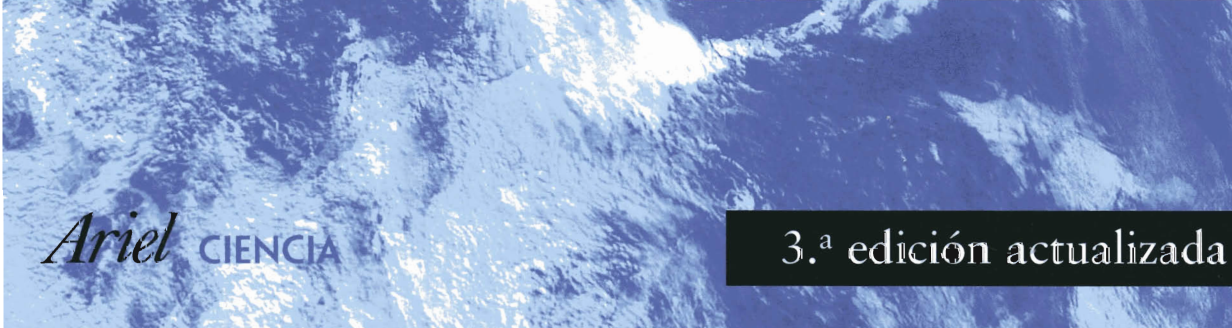
TELEDETECCIÓN AMBIENTAL

La observación de la Tierra desde el Espacio

Emilio Chuvieco Salinero



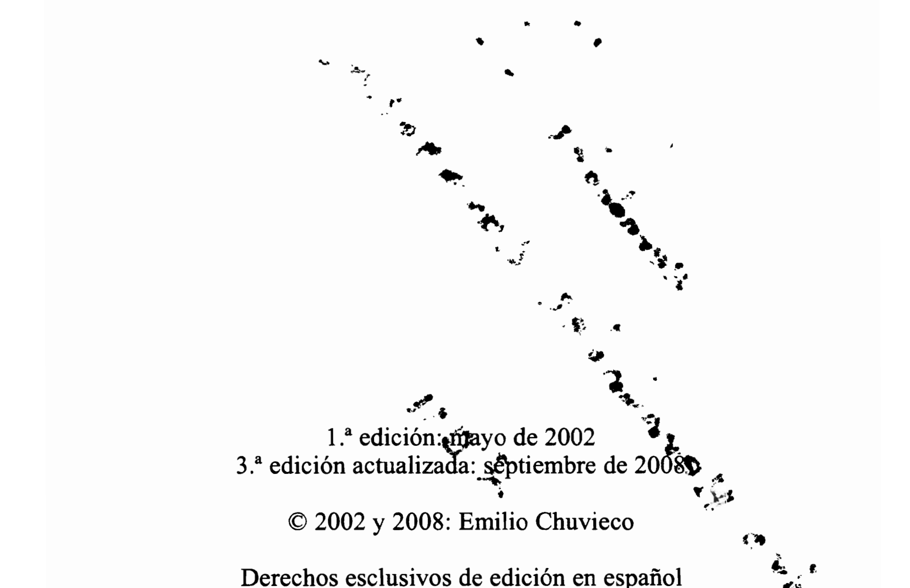
Emilio Chuvieco

Teledetección ambiental

La observación de la Tierra desde el Espacio







1.ª edición: mayo de 2002
3.ª edición actualizada: septiembre de 2008

ISBN: 978-84-344-8073-3

Depósito legal: B. 36.458-2008

Impreso en España por
Book Print Digital
Botànica, 176-178
08901 L'Hospitalet

A mis padres

A los niños no nacidos,
por las sonrisas que perdimos,
por los sueños que no dejamos despertar.

ÍNDICE

Presentación 13

PRIMERA PARTE

LA OBTENCIÓN DE LA IMAGEN

CAPÍTULO 1. **Nociones introductorias** 17
1. Definición y objetivos 17
2. Un poco de historia 21
3. Desarrollo actual 26
4. Aspectos legales de la teledetección 32
5. Las ventajas de la observación espacial 33
5.1. Cobertura global y exhaustiva de la superficie terrestre 34
5.2. Perspectiva panorámica 34
5.3. Observación multiescala y no destructiva 36
5.4. Información sobre regiones no visibles del espectro 36
5.5. Cobertura repetitiva 36
5.6. Transmisión inmediata 37
5.7. Formato digital 38
6. Fuentes bibliográficas 40

CAPÍTULO 2. **Principios físicos de la teledetección** 43
1. Fundamentos de la observación remota 43
2. El espectro electromagnético 45
3. Términos y unidades de medida 48
4. Principios y leyes de la radiación electromagnética 49
5. El dominio solar del espectro 52
5.1. Características de la radiación solar. Interacción con las cubiertas terrestres 52
5.2. Medios para obtener firmas espectrales 59
5.3. Bibliotecas espectrales 59
5.4. Comportamiento espectral de la vegetación en el espectro óptico . . . 60
5.5. El suelo en el espectro óptico 64
5.6. El agua en el espectro óptico 65
6. El dominio del infrarrojo térmico 67
6.1. Características de la radiación energética en el infrarrojo térmico . . . 67
6.2. Comportamiento espectral de la vegetación en el infrarrojo térmico . . 70
6.3. Los suelos y el agua en el dominio térmico 71
7. La región de las micro-ondas 73

7.1. Características de la radiación energética en la región de las micro-ondas . . . 73
7.2. Características de la vegetación en la región de las micro-ondas 80
7.3. Características del suelo y el agua en la región de las micro-ondas. . . 80
8. Interacciones de la atmósfera con la radiación electro-magnética 82
8.1. Absorción atmosférica . . . 83
8.2. Dispersión atmosférica . . . 84
8.3. Emisión atmosférica . . . 86

CAPÍTULO 3. **Sensores y satélites de teledetección** . . . 87
1. Tipos de sensores . . . 87
2. Resolución de un sistema sensor . . . 88
2.1. Resolución espacial . . . 88
2.2. Resolución espectral . . . 90
2.3. Resolución radiométrica . . . 92
2.4. Resolución temporal . . . 95
2.5. Resolución angular . . . 97
2.6. Relaciones entre los distintos tipos de resolución . . . 97
3. Sensores pasivos . . . 99
3.1. Cámaras analógicas . . . 99
3.2. Exploradores de barrido . . . 104
3.3. Exploradores de empuje . . . 107
3.4. Cámaras de vídeo . . . 109
3.5. Radiómetros de micro-ondas . . . 110
4. Sensores activos . . . 111
4.1. Radar . . . 111
4.2. Lídar . . . 119
5. Plataformas de teledetección espacial . . . 122
5.1. El programa Landsat . . . 124
5.1.1. Características orbitales . . . 125
5.1.2. Instrumentos de observación . . . 126
5.1.3. El futuro del programa Landsat . . . 130
5.2. El satélite SPOT . . . 132
5.3. El programa IRS . . . 135
5.4. Satélites comerciales de alta resolución . . . 137
5.5. Tiros-NOAA . . . 139
5.6. Satélites meteorológicos geoestacionarios . . . 142
5.7. Terra y Aqua . . . 144
5.8. DMSP . . . 149
5.9. Satélites de la Agencia Espacial Europea . . . 149
5.10. Otras misiones Radar . . . 151
5.11. Otros programas con sensores ópticos . . . 153
5.12. Programas con sensores hiper-espectrales . . . 155
5.13. El programa español de observación de la Tierra . . . 157

SEGUNDA PARTE

LA INTERPRETACIÓN DE LOS DATOS

CAPÍTULO 4. **Bases para la interpretación de imágenes de teledetección** . . . 161
1. Limitaciones para el empleo de la teledetección . . . 162

1.1. Información que brindan las imágenes 162
1.2. El coste de la información geográfica 162
1.3. El diálogo con los usuarios 164
2. Variables y tipos de interpretación 165
3. Organización de un proyecto de teledetección 168
3.1. Definición de objetivos 168
3.2. Escala y leyenda de trabajo 170
3.3. Selección de los materiales 175
3.3.1. Tipo de sensor 175
3.3.2. Fecha de adquisición 176
3.3.3. Soporte de las imágenes 177
3.4. Metodología de interpretación: ¿análisis visual o digital? 178
4. Fases en la interpretación 181

CAPÍTULO 5. **Interpretación visual de imágenes** 185
1. Familiarización con imágenes analógicas 185
1.1. Información incluida en los productos fotográficos 185
1.2. Identificación de algunos rasgos geográficos sobre la imagen 189
2. Criterios para la interpretación visual 189
2.1. Brillo 191
2.2. Color 193
2.3. Textura 196
2.4. Forma - Tamaño 199
2.5. Contexto espacial 200
2.6. Sombras 201
2.7. Patrón espacial 203
2.8. Visión estereoscópica 203
2.9. Período de adquisición 204
3. Elementos de análisis visual 205
3.1. Características geométricas de una imagen espacial 206
3.2. Efecto de la resolución espacial en el análisis visual 206
3.3. Efecto de la resolución espectral en el análisis visual 208
3.4. Interpretación de composiciones en color 213
3.5. Ejercicios de análisis multi-temporal 214
4. Algunos ejemplos de análisis visual 217
4.1. Cartografía geológica 217
4.2. Cobertura del suelo 217
4.3. Morfología urbana 220

CAPÍTULO 6. **Análisis digital de imágenes: correcciones y realces** 223
1. La matriz de datos en una imagen digital 223
2. Soporte y organización de la imagen 226
2.1. Soporte físico de una imagen 226
2.2. Formatos de grabación 227
3. Equipos de análisis digital de imágenes 229
4. Operaciones de utilidad general 232
4.1. Gestión de archivos 232
4.2. Utilidades para la visualización 234
4.3. Cálculo de estadísticas e histograma de la imagen 237
5. Realces y mejoras visuales 241

5.1. Ajuste del contraste 242
5.1.1. Tablas de referencia del color. 242
5.1.2. Compresión del contraste 244
5.1.3. Expansión del contraste. 245
5.2. Composiciones en color 251
5.3. Empleo del seudo-color 252
5.4. Filtrajes 254
5.4.1. Naturaleza de un filtro digital. 254
5.4.2. Filtros de paso bajo 258
5.4.3. Filtros de paso alto 259
6. Correcciones de la imagen 262
6.1. Fuentes de error en una imagen espacial 263
6.2. Correcciones radiométricas 266
6.2.1. Restauración de líneas o píxeles perdidos 266
6.2.2. Corrección del bandeado de la imagen 267
6.2.3. Cálculo de reflectividades. 270
6.2.4. Cálculo de temperaturas. 291
6.2.5. Detección de nubes 296
6.3. Correcciones geométricas 299
6.3.1. Introducción. 299
6.3.2. Corrección a partir de modelos orbitales 301
6.3.3. Corrección a partir de puntos de control 306

CAPÍTULO 7. **Análisis digital de imágenes: extracción de información temática** . 323
1. Generación de variables continuas 323
1.1. Técnicas de modelado en teledetección 323
1.1.1. Teledetección cualitativa y cuantitativa. 323
1.1.2. Tipo de modelos en teledetección. 325
1.1.3. Estimación empírica del contenido de agua en las plantas a partir de modelos empíricos 326
1.1.4. Estimación del contenido de agua a partir de modelos de simulación 331
1.2. Cocientes e índices de vegetación 337
1.3. Componentes principales. 346
1.4. Transformación «*Tasseled Cap*» (TTC) 352
1.5. Transformación IHS 355
1.6. Técnicas de análisis hiperespectral 359
1.6.1. Análisis de espectros 361
1.6.2. Clasificación angular 364
1.6.3. Reducción de la dimensionalidad de la imagen. 366
1.6.4. Análisis lineal de mezclas espectrales 366
1.7. Técnicas de fusión de datos 376
1.7.1. Enfoques en la fusión de imágenes 376
1.7.2. Obtención de imágenes híbridas. 377
1.7.3. Interpretación sintética con datos de distintas fuentes 380
1.7.4. Integración de resultados 381
2. Categorización de imágenes: clasificación digital 383
2.1. Introducción 383
2.2. Fase de entrenamiento 386
2.2.1. Conceptos básicos. 386

2.2.2. Método supervisado . . . 389
2.2.3. Método no supervisado . . . 393
2.2.4. Métodos mixtos . . . 396
2.2.5. Análisis de las estadísticas de entrenamiento . . . 397
2.3. Fase de asignación . . . 404
2.3.1. Clasificador de mínima distancia . . . 404
2.3.2. Clasificador de paralelepípedos . . . 405
2.3.3. Clasificador de máxima probabilidad . . . 407
2.3.4. Clasificadores en árbol . . . 413
2.3.5. Clasificadores basados en el contexto espacial . . . 416
2.3.6. Redes Neuronales Artificiales (RNA) . . . 422
2.3.7. Clasificación borrosa *(fuzzy classification)* . . . 427
2.4. Obtención y presentación de resultados . . . 430
2.4.1. Productos cartográficos . . . 430
2.4.2. Productos estadísticos . . . 432
3. Técnicas de análisis multitemporal . . . 433
3.1. El factor tiempo en los estudios de teledetección espacial . . . 433
3.2. Requisitos previos para el análisis multitemporal . . . 436
3.2.1. Ajuste geométrico . . . 436
3.2.2. Homogeneización radiométrica . . . 438
3.3. Técnicas para el análisis estacional . . . 439
3.4. Técnicas para la detección de cambios . . . 442
3.4.1. Composiciones de color multitemporales . . . 443
3.4.2. Diferencia entre imágenes . . . 445
3.4.3. Cocientes multitemporales . . . 447
3.4.4. Componentes principales . . . 448
3.4.5. Regresión . . . 450
3.4.6. Vectores multitemporales . . . 452
3.4.7. El problema de delimitar los umbrales . . . 454
3.4.8. Análisis multitemporal de imágenes clasificadas . . . 456
4. Determinación de la estructura espacial del territorio: la imagen como mosaico paisajístico . . . 460
4.1. Teledetección y ecología del paisaje . . . 460
4.2. Técnicas para medir la estructura espacial de una imagen . . . 462
4.2.1. Medidas de la variación espacial en imágenes de intervalo . . . 462
4.2.2. Medidas de la variación espacial en imágenes clasificadas . . . 470
4.2.3. Dinámica de la estructura espacial del paisaje . . . 475

CAPÍTULO 8. **Verificación de resultados** . . . 481
1. Necesidad de verificar resultados . . . 481
2. Medidas de la fiabilidad . . . 482
3. Fuentes de error en una clasificación temática . . . 484
3.1. Limitaciones del sensor . . . 485
3.2. Métodos de análisis . . . 485
3.3. Estructura del territorio . . . 486
3.4. Proceso de verificación . . . 488
4. Diseño del muestreo para la verificación . . . 491
4.1. Distribución de la información . . . 491
4.2. Unidad de muestreo . . . 492
4.3. Tipos de muestreo . . . 492

4.4. Tamaño de la muestra 495
5. Recogida de la información 497
6. Medidas del error para variables continuas 500
7. Medidas del error para imágenes clasificadas 501
7.1. La matriz de confusión 501
7.2. Fiabilidad global 503
7.3. Fiabilidad del usuario y del productor 504
7.4. El estadístico kappa 505
7.5. Normalización de la matriz de confusión 507
7.6. Validación para clases binarias 509
8. Verificación de análisis multitemporales 511

CAPÍTULO 9. **Teledetección y sistemas de información geográfica** 513
1. Necesidad de los SIG 513
2. Paralelismo y convergencia 515
3. Requisitos técnicos comunes 517
4. Los SIG como apoyo a la teledetección 518
5. La teledetección como fuente de datos para un SIG 519
5.1. El acceso a la información geográfica 519
5.2. Fase de inventario 520
5.3. El problema de la actualización 522
6. Integración de imágenes en un SIG 523

Referencias bibliográficas 529

ANEXOS

1. **Abreviaturas utilizadas en el manual** 573

2. **Glosario** 577

3. **Índice temático** 583

4. **Fuentes adicionales de información** 591

5. **Situación y características de las imágenes utilizadas en los capítulos 6 y 7** . 595

PRESENTACIÓN

La observación de la Tierra desde el espacio ha experimentado en los últimos años un vertiginoso desarrollo, llegando a ser un aliado cada vez más imprescindible en el seguimiento de procesos ambientales de gran impacto para nuestro planeta, como sería el calentamiento climático, la desertificación, la deforestación, o la capa de ozono. En ésta como en otras nuevas tecnologías, resulta clave realizar un importante esfuerzo en la educación y formación continuada. Aprovechar el flujo de información que proporcionan los satélites de observación terrestre requiere conocer los fundamentos de la adquisición, su sentido biofísico, los criterios de interpretación más destacados, su engarce con otras fuentes de información más convencionales.

Este texto es fruto de actualizar la edición publicada en el año 2002, que previamente había sido publicada con el título *Fundamentos de Teledetección Espacial* en 1990 y 1996. Aunque puede adaptarse a estudiantes y profesionales de distintos grados, hemos intentado darle una orientación ambiental.

Hemos mantenido el esquema general de las ediciones anteriores de esta obra, poniendo al día los aspectos que han sufrido peor el paso del tiempo, y extendiendo o simplificando, según el caso, otros apartados, con el ánimo de mejorar el enfoque didáctico del libro.

La notación que incluye el texto también respeta los criterios de las anteriores ediciones. Las fórmulas se citan entre llaves { }, con dos números separados por un punto: el primero hace referencia al capítulo en donde se incluye y el segundo al orden dentro de ese capítulo. De forma similar se citan las figuras, entre paréntesis ( ) y precedidas de la indicación fig., también con dos números. Aquellas que aparecen con un asterisco * identifican imágenes en color y están situadas en el encarte central del libro. Por último, en ocasiones se sugiere al lector acudir a otros capítulos para recabar información adicional. Esto se hará indicando la numeración de ese capítulo entre paréntesis ( ). Al final de la obra, se mantienen, aunque algo enriquecidos, los apéndices donde el lector podrá encontrar información adicional sobre esta técnica, un glosario de términos y un índice temático.

Al igual que en ediciones anteriores de esta obra, mi trabajo ha estado en todo momento apoyado por los comentarios y sugerencias de alumnos, compañeros de trabajo y colegas en la docencia o investigación de esta materia. Aunque citarlos a todos aumentaría excesivamente la obligada brevedad de un prólogo, resulta de justicia reseñar a quienes han dedicado generosamente su tiempo a revisar diversos borradores de esta obra. En lo que respecta a esta edición, han resultado de especial

interés los comentarios de David Riaño, Javier Martínez-Vega, Angela de Santis, Marta Yebra, Mariano García y Hector Nieto. De las anteriores, no puedo olvidar la aportación de José Sancho, Javier Salas, Pilar Martín, Inmaculada Aguado, Vicente Caselles, Xavier Pons y Alicia Palacios.

Como dice un autor norteamericano, Leo Trese, «nuestra existencia será poco feliz si no tenemos la convicción de que la vida está llena de sentido. Todo lo que hacemos, consciente y voluntariamente, lo hacemos por un fin; existe una razón por la que actuamos así». Mi propósito al escribir este texto, al igual que ocurrió con las ediciones anteriores, ha sido facilitar la enseñanza de esta disciplina a estudiantes y profesionales de distintas procedencias, tanto en nuestro país, como los queridos latinoamericanos. Más allá del esfuerzo que esta tarea lleva consigo, mi mayor alegría ha sido recibir comentarios sobre su utilidad didáctica. Espero que esta nueva edición siga contribuyendo a esa tarea de formación, no sólo porque la docencia es mi principal actividad, sino porque estoy convencido de que la educación es la mejor contribución que podemos realizar al desarrollo de los pueblos.

Alcalá de Henares, mayo de 2008
EMILIO CHUVIECO SALINERO

Primera parte

LA OBTENCIÓN DE LA IMAGEN

CAPÍTULO 1

NOCIONES INTRODUCTORIAS

> «Es grandioso el espectáculo de las fuerzas variadas de la vida que Dios infundió en los seres creados haciéndoles desarrollarse en formas cada vez más bellas y admirables.»
>
> CHARLES DARWIN, *El origen de las especies*

1. **Definición y objetivos**

Volar ha sido, desde épocas muy remotas, uno de los sueños más intensamente anhelados por la Humanidad. Pese a la persistencia del intento, sólo en fechas recientes se ha dispuesto de los medios técnicos necesarios para hacer realidad este deseo. Desde ese momento, el ritmo de la innovación tecnológica ha sido vertiginoso, lo que nos ha permitido enriquecer notablemente nuestro conocimiento sobre el planeta y sus habitantes.

Uno de los principales acicates de esta aventura aérea ha sido la búsqueda de una nueva visión de los paisajes terrestres. El afán de remontar la limitada perspectiva de la visión humana es evidente ya desde los inicios de la aeronáutica, y llega a jugar actualmente un destacado papel en la investigación espacial.

Esa observación remota de la superficie terrestre constituye el marco de estudio de la teledetección. Este vocablo es una traducción latina del término inglés *remote sensing*, ideado a principios de los sesenta para designar cualquier medio de observación remota, si bien se aplicó fundamentalmente a la fotografía aérea, principal sensor de aquel momento. En sentido amplio —y así se tratará en este libro—, la teledetección no engloba sólo los procesos que permiten obtener una imagen, sino también su posterior tratamiento e interpretación. Actualmente se está desvaneciendo bastante la frontera entre teledetección aérea y espacial, tanto porque la primera emplea cada vez más sensores digitales, como porque la segunda ofrece niveles de detalle antes sólo logrados desde cámaras aeroportadas. Por ello, la mayor parte de las técnicas tratadas en este libro pueden aplicarse indistintamente a imágenes adquiridas desde avión o desde satélite, si bien nos centraremos principalmente en sensores montados sobre plataformas espaciales. Se asume que el lector está familiarizado con las técnicas de foto-interpretación, ya que han venido siendo comunes en la mayor parte de las facultades con orientación medio ambiental.

Si hemos definido la teledetección como aquella técnica que permite adquirir imágenes de la superficie terrestre desde sensores aéreos o espaciales, estamos asumiendo que entre suelo y sensor existe una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial, ya por emisión propia. A su vez, es preciso que ese haz energético recibido por el sensor sea almacenado convenientemente, bien a bordo del satélite, bien en las estaciones receptoras, de cara a que pueda interpretarse para una determinada aplicación. Como antes comentamos, ese análisis de la información recibida se incluye también —en sentido amplio— dentro del estudio de la teledetección, aunque esté más allá de los procesos de adquisición propiamente dichos. No obstante, constituye un capítulo fundamental para nuestros intereses, por cuanto esta obra se dirige más a quienes explotan la información adquirida por estos sensores que a quienes diseñan los sensores o las plataformas que los sustentan.

Tal y como se concibe en la presente obra, un sistema de teledetección espacial incluye los siguientes elementos (fig. 1.1):

1. Fuente de energía, que supone el origen de la radiación electro-magnética que detecta el sensor. Puede tratarse de un foco externo a éste, en cuyo caso se habla de teledetección pasiva, o de un haz energético emitido por el sensor (teledetección activa). La fuente de energía más importante, obviamente, es el Sol, pero también puede realizarse teledetección a partir de la energía emitida por los mismos objetos observados, o desde fuentes artificiales.
2. Cubierta terrestre, formada por distintas masas de vegetación, suelos, agua o construcciones humanas, que reciben la señal energética procedente de (1), y la reflejan o emiten de acuerdo a sus características físicas.
3. Sistema sensor, compuesto por el sensor, propiamente dicho, y la plataforma que lo alberga. Tiene como misión captar la energía procedente de las cubiertas terrestres, codificarla y grabarla o enviarla directamente al sistema de recepción.
4. Sistema de recepción-comercialización, en donde se recibe la información transmitida por la plataforma, se graba en un formato apropiado, y, tras las oportunas correcciones, se distribuye a los interesados.
5. Intérprete, que convierte esos datos en información temática de interés, ya sea visual o digitalmente, de cara a facilitar la evaluación del problema en estudio.
6. Usuario final, encargado de analizar el documento fruto de la interpretación, así como de dictaminar sobre las consecuencias que de él se deriven.

El símil de la visión humana puede ayudar a entender el significado de estos componentes. El ojo humano (3) recibe un haz energético procedente de los objetos exteriores (2) por reflejo de la luz solar (1). Esa señal se transmite al cerebro (4), que es capaz de formar una serie de imágenes sobre el mundo real que le circunda. El individuo que observa es a la vez intérprete (5) y usuario final (6) de la imagen detectada, lo que le permite tomar decisiones sobre su propio comportamiento. En otras palabras, la visión humana forma un sistema de teledetección —muy sofisticado por cierto—, puesto que nos permite caracterizar con mucho detalle los objetos que observamos.

Sin embargo, nuestra percepción visual presenta también algunas limitaciones. Por un lado, se restringe por la sensibilidad espectral de nuestras células sensoras, que

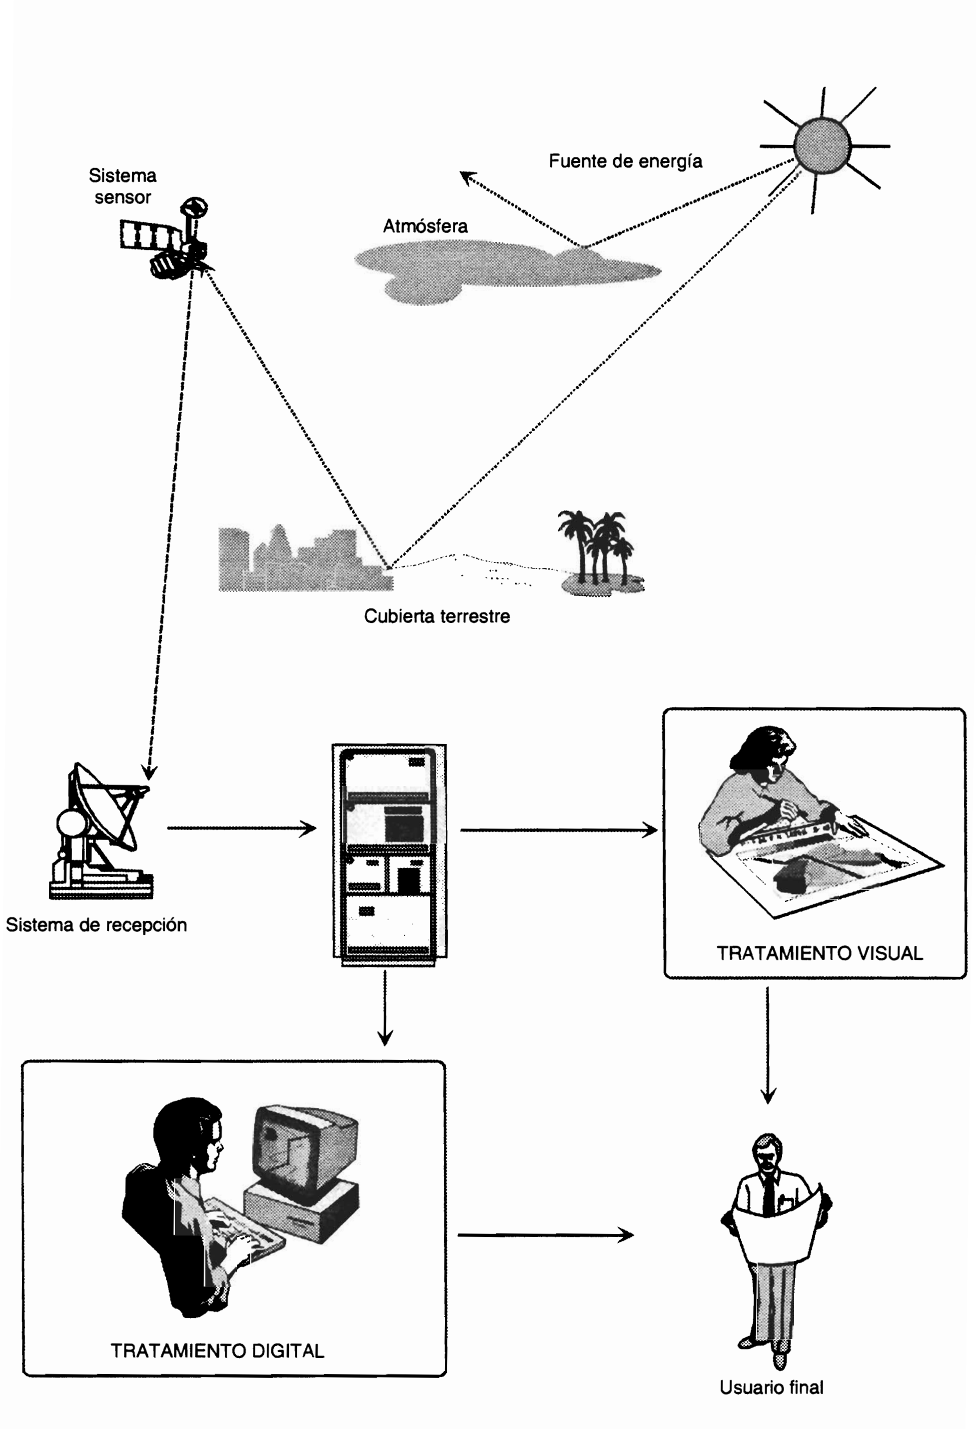


FIG. 1.1. *Componentes de un sistema de teledetección.*

sólo nos permiten apreciar un determinado tipo de energía, denominado, por esa razón, espectro visible. Otras formas energéticas, como el calor, no son observables visualmente, por lo que parece conveniente contar con unos «ojos artificiales» que amplíen nuestras propias posibilidades. Por otro lado, el campo de visión humano está limitado por nuestra propia estatura, o a la que podemos adquirir desde observatorios naturales, por lo que abarca un pequeño radio. Además, se trata de una perspectiva oblicua. Ambos factores dificultan observar fenómenos que afectan a amplios territorios, como inundaciones o procesos de desertificación, donde las estimaciones visuales pueden ser imprecisas. Para paliar estas limitaciones, se ha acudido a sensores artificiales, montados sobre plataformas situadas a una cierta altitud. Con ellos, se tiene acceso a tipos de energía no visibles (ultravioleta, infrarrojo, micro-ondas), y, además, desde una nueva perspectiva, vertical y panorámica. Esta nueva información expande notablemente nuestro conocimiento del medio que nos rodea, facilitando la interpretación de múltiples procesos que afectan al Planeta.

El creciente empleo de distintos sensores de observación terrestre está originando no sólo una enorme cantidad de información, sino también una nueva forma de estudiar la superficie terrestre. La teledetección, junto a las técnicas anejas de almacenamiento y proceso de la información geográfica, permite disponer de una masa ingente de datos sobre el territorio, algunos de ellos accesibles en tiempo real. Para aprovechar con fruto estas técnicas, el recurso a los ordenadores electrónicos resulta casi inevitable. Una vez salvado el necesario entrenamiento, estos equipos amplían notablemente nuestra capacidad de análisis: ayudan a elaborar una interpretación rápida y económica del problema bajo estudio, a la vez que permiten abordar análisis integrados, difícilmente viables con otros medios tradicionales. En definitiva, y gracias a estos recursos, podemos cada día poner más el énfasis sobre el planteamiento de modelos y el análisis de resultados —tareas éstas donde la inteligencia humana resulta insustituible—, librándola de otras labores mecánicas (acopio, proceso y ordenación de datos), que han consumido hasta hace pocos años las mejores fuerzas del investigador.

De acuerdo con el esquema antes enunciado, esta obra engloba el estudio de los distintos elementos que forman un sistema de teledetección. En primer lugar, se analizan los procesos que permiten obtener las imágenes espaciales: principios físicos de transmisión de la energía (cap. 2), y técnicas de adquisición de imágenes, con un breve repaso de los principales proyectos de observación terrestre (cap. 3). El resto de los capítulos se centran en la interpretación —tanto visual como digital— de las imágenes, punto crucial para los interesados en las aplicaciones de esta técnica (caps. 4 a 7). La verificación de los resultados obtenidos en esa fase se aborda en el capítulo 8, para concluir la obra con el 9, a modo de epílogo, dedicado al estudio de la conexión entre la teledetección y los Sistemas de Información Geográfica, dentro de un planteamiento integrado del análisis medio ambiental. Estos capítulos se preceden de éste, que incluye unos comentarios sobre el pasado, presente y desarrollo previsible de la teledetección, incluyendo algunos aspectos legales que pueden ayudar a enmarcar conflictos internacionales derivados de esta observación terrestre.

2. Un poco de historia

La teledetección es una técnica aplicada, y como tal muy dependiente del estado de desarrollo tecnológico existente en cada momento. Por cuanto conjuga aspectos muy variados —óptica y detectores del sensor, plataforma que lo sustenta, sistemas de transmisión, equipos de tratamiento, etc.—, las formas de teledetección han variado ostensiblemente en las últimas décadas (fig. 1.2). El crecimiento ha sido realmente vertiginoso, facilitando una progresión muy notable, tanto en la cantidad, como en la variedad y calidad de la información disponible para campos científicos muy variados.

Las primeras experiencias de teledetección se remontan a 1859, cuando Gaspar Félix de Tournachon obtuvo las primeras fotografías aéreas desde un globo cautivo (fig. 1.3). Al año siguiente, James Wallace repitió la experiencia sobre la ciudad de Boston, poniéndose en evidencia el interés de la nueva perspectiva aérea para un conocimiento más detallado de la organización urbana.

En los años posteriores, se produjo un importante desarrollo de la observación fotográfica desde avión, gracias a los progresos realizados en ópticas y emulsiones. En 1909, Wilbur Wright adquirió la primera fotografía aérea, abriendo el camino a una larga historia de observación desde plataformas remotas. La primera cámara aérea propiamente dicha se desarrolló durante la Primera Guerra Mundial, concretamente en 1915, por J.T.C. Moore-Brabazon. La importancia estratégica de este escrutinio quedó pronto en evidencia, desarrollándose notablemente las técnicas de adquisición y procesado fotográfico (Brookes, 1975).

El segundo conflicto bélico implicó un notable desarrollo de las técnicas de teledetección aérea. El progreso se orientó a mejorar la óptica de las cámaras de reconocimiento, así como las emulsiones utilizadas (de esta época proceden las primeras películas en infrarrojo, desarrolladas por *Kodak Research Laboratories*). Asimismo, se introdujeron nuevos sensores, como el radar, y se mejoraron los sistemas de comunicación. Por otro lado, la aeronáutica prosperó notablemente, lo que aseguró mayor estabilidad a las plataformas de observación.

Todas estas innovaciones se aplicaron posteriormente para usos civiles, desarrollándose las primeras aplicaciones de esta exploración aérea para el conocimiento y control de los recursos naturales. En los años de posguerra se perfeccionaron los sistemas radar, introduciéndose el radar lateral aerotransportado (SLAR), y se pusieron a punto los sensores térmicos de barrido.

A finales de los años cincuenta, el desarrollo de los sistemas de navegación permitió concebir los primeros ingenios espaciales. La denominada «guerra fría» dirigió hacia el espacio uno de sus objetivos preferentes, alentándose, desde uno y otro bando, una intensa investigación en estos temas. La primera fotografía espacial fue tomada en 1947 desde unos 200 km de altura sobre el estado de Nuevo México (EE.UU.) utilizando un cohete V-2 capturado a los alemanes. Diez años más tarde, en 1957, se lanzó el primer satélite artificial, el Sputnik, al que han seguido una larga serie de misiones civiles y militares, que han permitido no sólo la exploración de nuestro Planeta, sino también de la Luna y los planetas vecinos.

El grave incidente diplomático ocurrido en 1960 tras la captura por parte de la entonces Unión Soviética de un avión de espionaje estadounidense, el U-2 (fig. 1.4),

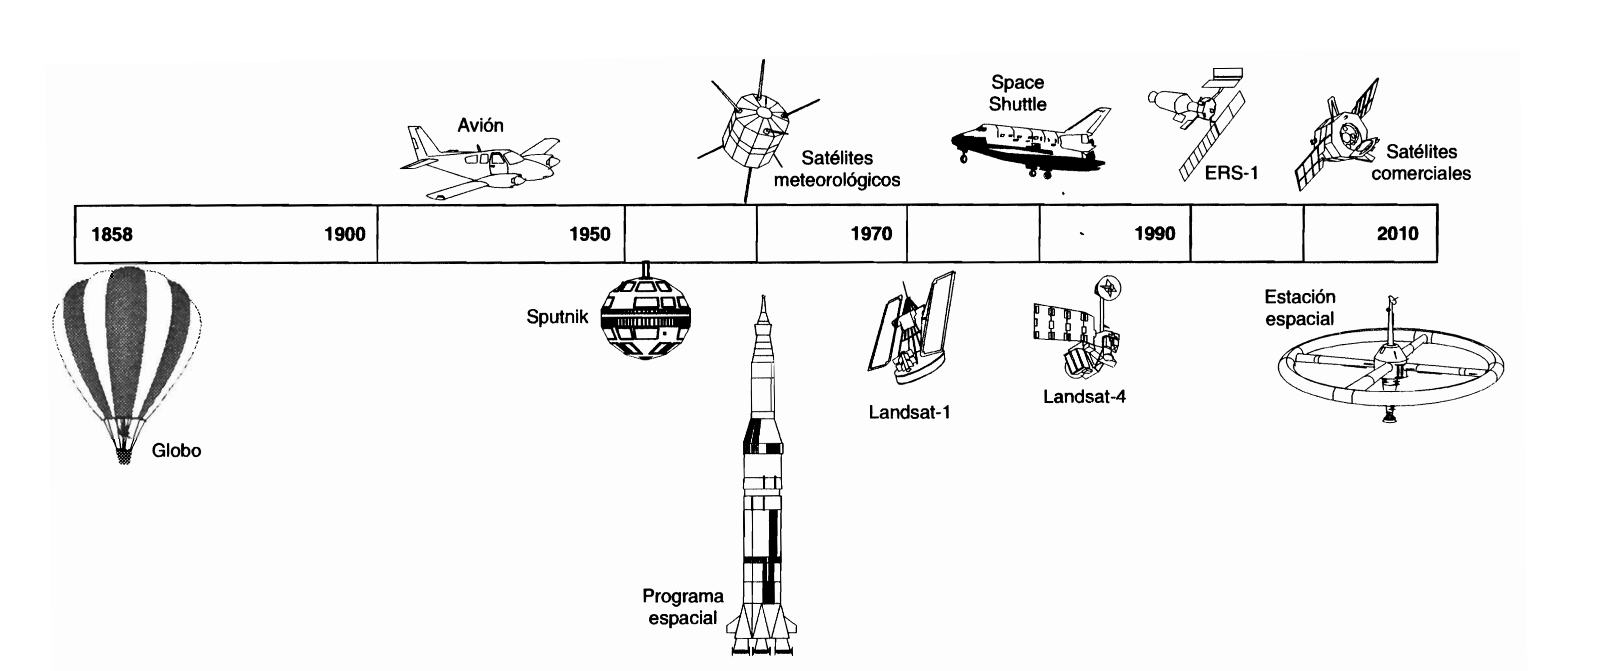


FIG. 1.2. *Evolución histórica de los sistemas de teledetección.*

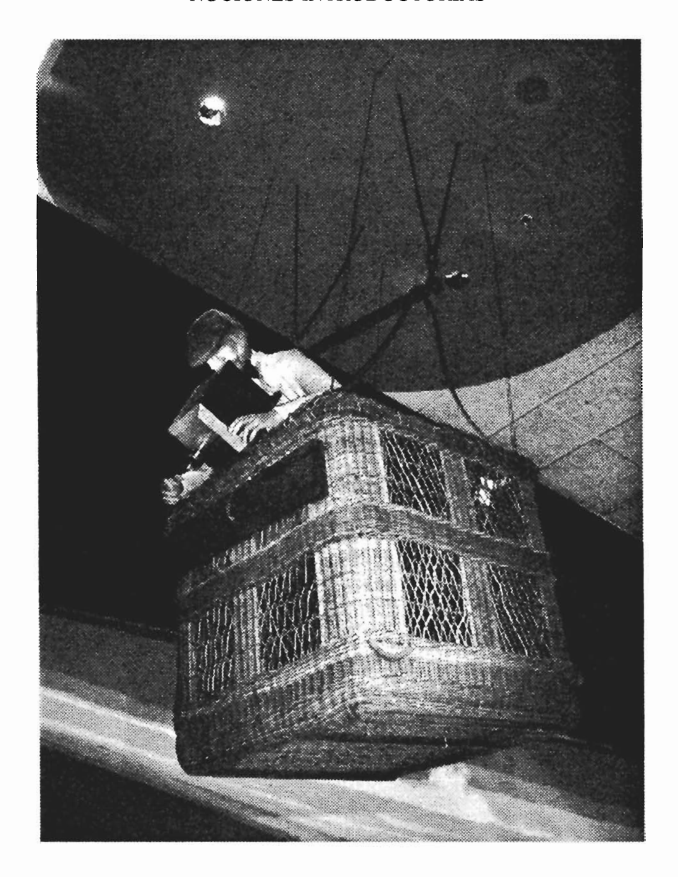


FIG. 1.3. *Observación fotográfica desde globos (fotografía tomada en el* Air and Space Museum *de Washington).*

subraya el interés de la administración Einsenhower de la importancia de desarrollar un sistema de reconocimiento militar basado en vehículos espaciales, que ya se había iniciado en 1959 con el lanzamiento del satélite CORONA KH-1 a los que siguieron una larga lista de misiones de reconocimiento militar (ARGON, LANYARD, etc.). Estas plataformas han tenido un papel clave en las relaciones entre los bloques militares (Leghorn y Herken, 2001), si bien han sido completamente opacas a la utilización civil, hasta su desclasificación en 1995 (de las imágenes adquiridas entre 1960 y 1972).

En el terreno civil, conviene destacar el lanzamiento del primer satélite de observación de la Tierra en 1960, el TIROS-1, pionero de múltiples misiones de observación meteorológica, que han permitido un conocimiento y control más ajustados de las condiciones atmosféricas, evitando, o paliando al menos, graves catástrofes naturales. Junto a ellos, en los años sesenta también se impulsaron misiones tripuladas que permitieron adquirir las primeras fotografías espaciales de uso civil, durante las misiones del Mercury (1961), Gemini-Titán (1965) y Apollo (desde 1968). En el Apollo-9 (1969) se abordó el primer experimento multi-espectral, denominado S065, compuesto por cuatro cámaras Hasselblad con distintos filtros (Short, 2006).

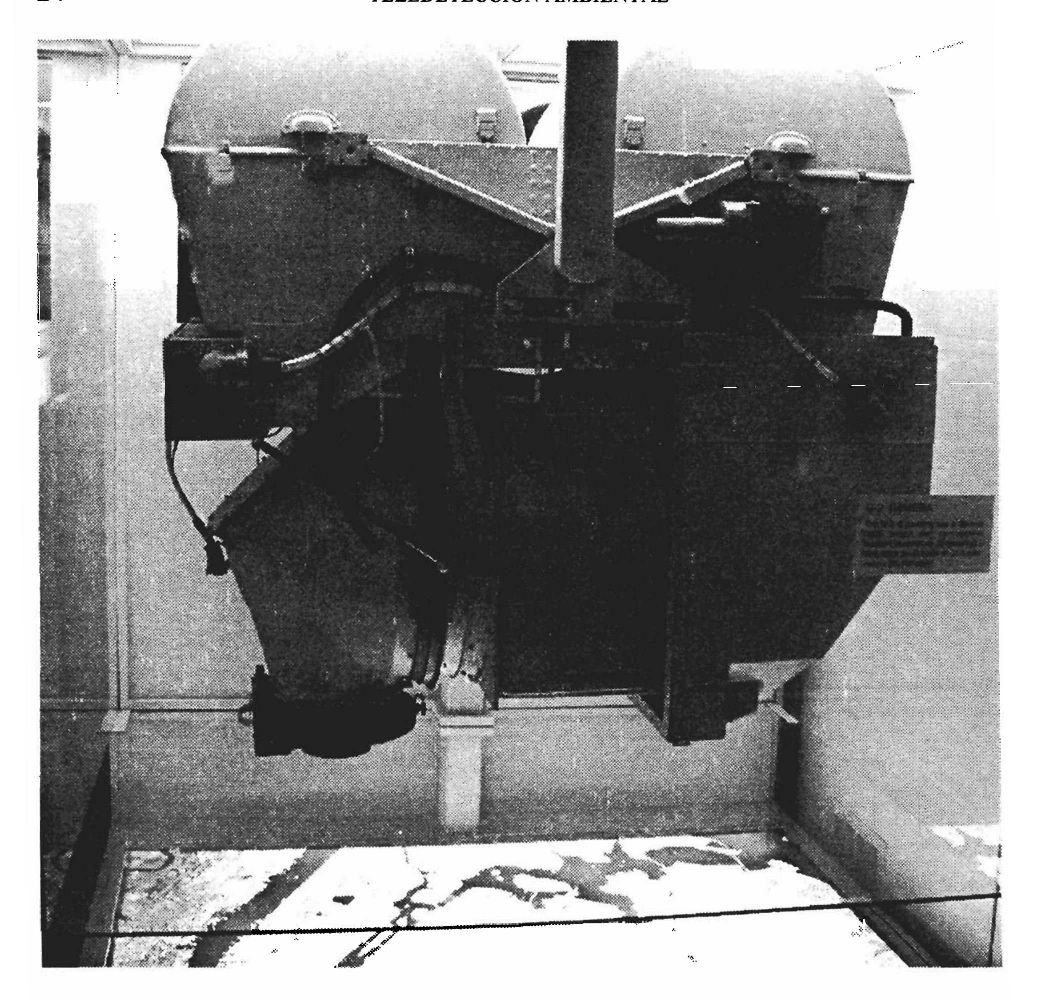


FIG. 1.4. *Cámara fotográfica instalada en el avión de reconocimiento U-2 (fotografía tomada en el* Air and Space Museum *de Washington).*

Todas estas experiencias, junto al bagaje aportado por los satélites meteorológicos, hicieron concebir a la NASA proyectos dedicados exclusivamente a la cartografía y evaluación de los recursos naturales. El 23 de julio de 1972 supuso la culminación de esta tendencia, con el feliz lanzamiento del primer satélite de la serie ERTS (*Earth Resources Technollogy Satellite*). Este proyecto, bautizado Landsat con la puesta en órbita del segundo satélite en 1975, resulta el más fructífero hasta el momento para aplicaciones civiles de la teledetección (ver sección 3.5.1). A partir de la serie Landsat, el interés de la comunidad científica internacional por esta técnica ha crecido exponencialmente, contándose por miles los estudios desarrollados —sobre temáticas muy diversas, de inundaciones a incendios, erupciones volcánicas o inventarios agrícolas— sobre las imágenes proporcionadas por estos satélites.

A la serie Landsat siguieron otros proyectos específicamente diseñados por la NASA para la observación medio ambiental (Chuvieco y Justice, 2008). Los más co-

nocidos son el laboratorio espacial tripulado Skylab (1973: NASA, 1977), el satélite oceanográfico Seasat (1978: Ford, 1980), o el de investigación térmica HCMM (1978: Short y Stuart, 1982). A estos proyectos de la NASA, siguieron los diseñados por otras agencias espaciales, como el satélite franco-belga SPOT, lanzado por vez primera en 1986, el japonés MOS-1 (1987), el indio IRS-1 (1988), el satélite europeo ERS-1 (1991) y los rusos Soyuz y Salut.

En las últimas décadas las misiones de teledetección se han incrementado exponencialmente, como veremos más tarde (cap. 3.5). A las agencias espaciales con mayor experiencia en observación de la Tierra, se han unido otras que han aprovechado su desarrollo tecnológico y la reducción de costes en el diseño de sensores y vehículos de lanzamiento. Esto ha permitido a Canadá, Brasil, Argentina, China, Corea del Sur, o Israel, por citar algunos ejemplos, poner en órbita sensores de teledetección, lo que ha incrementado la disponibilidad de datos y permitido reducir costes de adquisición para el usuario final. Además, no podemos dejar de mencionar el creciente papel de la iniciativa privada, que ha constituido consorcios para diseñar y explotar satélites de teledetección. Estos satélites comerciales de teledetección, aunque todavía escasos, se encuentran en la vanguardia de la tecnología y permiten apuntar un amplio crecimiento de sus aplicaciones operativas. Entre ellas caben citar, junto a algunas ya consolidadas como la cartografía, gestión ambiental o localización de instalaciones, otras que afectan a sectores apenas involucrados previamente con la teledetección (tabla 1.1), como pueden ser los medios de comunicación (fig. 1*), las empresas de seguros, los consorcios turísticos, las ONG responsables de la asistencia en situaciones de catástrofe, los grupos ambientalistas, o los comités internacionales que velan por los derechos humanos y apoyan actividades humanitarias, asistencia a refugiados, etc. (Baker, 2001; Baker *et al.*, 2001; O'Connell y Lachman, 2001).

En cuanto a las tendencias previsibles en un inmediato futuro, podemos citar la mayor disponibilidad de datos, gracias a las nuevas misiones que se están diseñando, pero también a las reducciones del coste y la mayor facilidad para transmitir esos datos a través de internet. La mayor parte de los proveedores facilitan imágenes utilizando servidores FTP, lo que permite disponer de ellas en un tiempo muy cercano a la adquisición, y en bastantes casos son de acceso gratuito. En cuanto a los sensores, parece previsible que sigan mejorándose los distintos tipos de resolución, y especialmente la espacial y espectral, que permitan disponer de varios satélites con resolución submétrica y capacidad hiperespectral. En este terreno, también ha jugado un papel destacado la apertura de la observación de la Tierra a corporaciones privadas, que han realizado notables inversiones para mantener sistemas operativos de teledetección espacial, que reemplacen de alguna forma las carencias de la observación aérea, facilitando un sistema de observación global en condiciones estándar. La popularización de estas imágenes de alta resolución a través de los servidores de dominio público, el más destacado de los cuales es Google Earth (Butler, 2006), ha permitido extender también el rango de usuarios de estas tecnologías. Finalmente, conviene también señalar la importancia de nuevas tecnologías de observación terrestre, que hasta hace muy poco eran exclusivas de sensores experimentales, y ya se están montando sobre plataformas aéreas y espaciales equipos lídar, radares interferométricos, etc., que abren la puerta asimismo a nuevas posibilidades en el empleo de la teledetección.

TABLA 1.1. *Comparación entre aplicaciones convencionales y nuevas de la teledetección (adaptado de Baker, 2001)*

Usuarios tradicionales	*Nuevos usuarios*
Gobiernos: — Planificadores civiles. — Fuerzas armadas. — Servicios de inteligencia. — Centros científicos. — Entidades regionales y locales.	*Medios de comunicación:* — De información general (televisiones, periódicos). — De información específica (revistas). — Editoriales.
Organizaciones internacionales: — Agencias de la ONU (refugiados, medioambiente...). — Programas de cambio global. — Centros regionales (p. ej., UEO).	*ONG:* — Ambientalistas. — Control de armamentos, desarme. — Ayuda humanitaria. — Derechos humanos. — Gestión de catástrofes.
Empresas: — Extracción de recursos (petróleo, gas...). — Gestión de recursos (forestales, agrícolas...). — Aerofotografía. — Diseño y lanzamiento de sensores. — Diseño y venta de *software* de tratamiento digital. — Empresas de SIG.	*Empresas:* — Redes de distribución (electricidad, agua...). — Seguros. — Agricultura de precisión. — Evaluación de impacto ambiental. — Promoción turística.
Universidades y centros de investigación: — Departamentos de Geografía, Geología, Biología, Ing. Geodésica, Agronomía, etc. — Centros de Teledetección. — Departamentos de Física, Informática, Ing. Telecomunicación.	*Universidades y centros de investigación:* — Departamentos de Arqueología, transportes. — Centros multimedia. — Departamentos de Geopolítica.
Organizaciones profesionales: — Teledetección. — Campos afines a las aplicaciones.	*Clientes finales:* — Mercado inmobiliario. — Decoración.

3. Desarrollo actual

Pese a la juventud de esta tecnología, son ya numerosos los centros de producción, enseñanza e investigación que trabajan activamente en este campo. Las tendencias presentes parecen confirmar un creciente desarrollo de su aplicación, tanto en países desarrollados como en aquellos con una situación tecnológica más deficiente. Las últimas décadas, y muy especialmente los últimos años, han implicado una disponibilidad creciente de datos provenientes de sensores muy variados, y de misiones espaciales muy diversificadas, aumentando exponencialmente las investigaciones y las aplicaciones operativas de esta técnica.

Un breve repaso por áreas geográficas, nos servirá para tener una evaluación más precisa de las diversidades geográficas en la implantación de esta técnica. En los

apéndices y la web se incorpora información adicional sobre las instituciones que se citan a lo largo de los siguientes párrafos.

Como parece lógico por el papel pionero que EE.UU. ha tenido en los satélites de teledetección, en ese país el desarrollo de esta técnica es especialmente relevante, tanto académica como comercialmente. De acuerdo a un informe sobre la privatización del proyecto Landsat remitido al Congreso de Estados Unidos (O.T.A., 1984), ya a principios de los ochenta existían en ese país más de 50 organizaciones comerciales dedicadas al empleo de la teledetección espacial. En más de 18 estados se utilizaban datos Landsat para la construcción de sus sistemas de información territorial, y sólo en 2 no se habían constatado estudios realizados a partir de imágenes de este satélite. Con datos de 1977, este mismo informe registraba 590 profesores e investigadores universitarios trabajando en teledetección. En ese mismo año se ofrecían 137 cursos sobre esta técnica en universidades americanas, con un total de 2.906 inscritos. A finales de los ochenta, se contabilizaban 549 cursos ofrecidos en teledetección por más de 300 departamentos de 125 universidades (Kiefer, 1988). Como es lógico, la situación actual supone un desarrollo mucho mayor, habiéndose extendido prácticamente a todos los estados y en las más variadas instituciones de la Administración, la utilización de esta tecnología.

Buena parte de las iniciativas profesionales se canalizan a través de la *American Society for Photogrammetry and Remote Sensing*, que cuenta con unos 7.000 afiliados y casi doscientas empresas y socios institucionales. Entre los socios, un 30 % pertenecen al sector privado, lo que da idea de la actividad comercial en este campo. Esta asociación publica mensualmente la revista *Photogrammetric Engineering and Remote Sensing*, una de las más prestigiosas de teledetección. Otras instituciones de gran actividad son los diversos centros NASA (especialmente *Goddard,* en Maryland, y *Ames Research Center* y *Jet Propulsion Laboratory*, en California). Entre los departamentos universitarios, casi todas las universidades del país tienen un programa de investigación y docencia activo en esta materia. Cuentan con gran tradición el *Laboratory for Applications of Remote Sensing* (LARS) de la Universidad de Purdue (Indiana), el *Institute for Environmental Studies* de la Universidad de Wisconsin-Madison, y la *Remote Sensing Unit* de la Universidad de California en Santa Barbara, por citar sólo los más significativos, si bien actualmente hay otros departamentos más activos en estos temas, con los de Geografía de las Universidades de Maryland, Carolina del Sur y Boston.

De gran importancia también es el *U.S. Geological Survey*, que se encarga, a través del *EROS Data Center,* de la distribución de una amplia colección de imágenes tomadas por distintos sensores. La NASA (*National Aeronautics and Space Administration*) y NOAA (*National Oceanic and Atmospheric Administration*) mantienen la distribución de sus propios programas (actualmente el Terra-Aqua y las series meteorológicas NOAA y GOES, entre otras).

En cuanto al mercado de productos de teledetección, y de acuerdo a un informe de la oficina de asesoramiento tecnológico del Congreso de los años noventa, se estimaba que el mercado de teledetección podría situarse entre 150 y 200 millones de dólares anuales para los datos brutos, y unos 500 millones para los servicios de valor añadido, con un incremento previsto de entre el 15 y el 20 % anual (O.T.A., 1994). El desarrollo de ese mercado se ha visto muy ligado al creciente recurso a la información

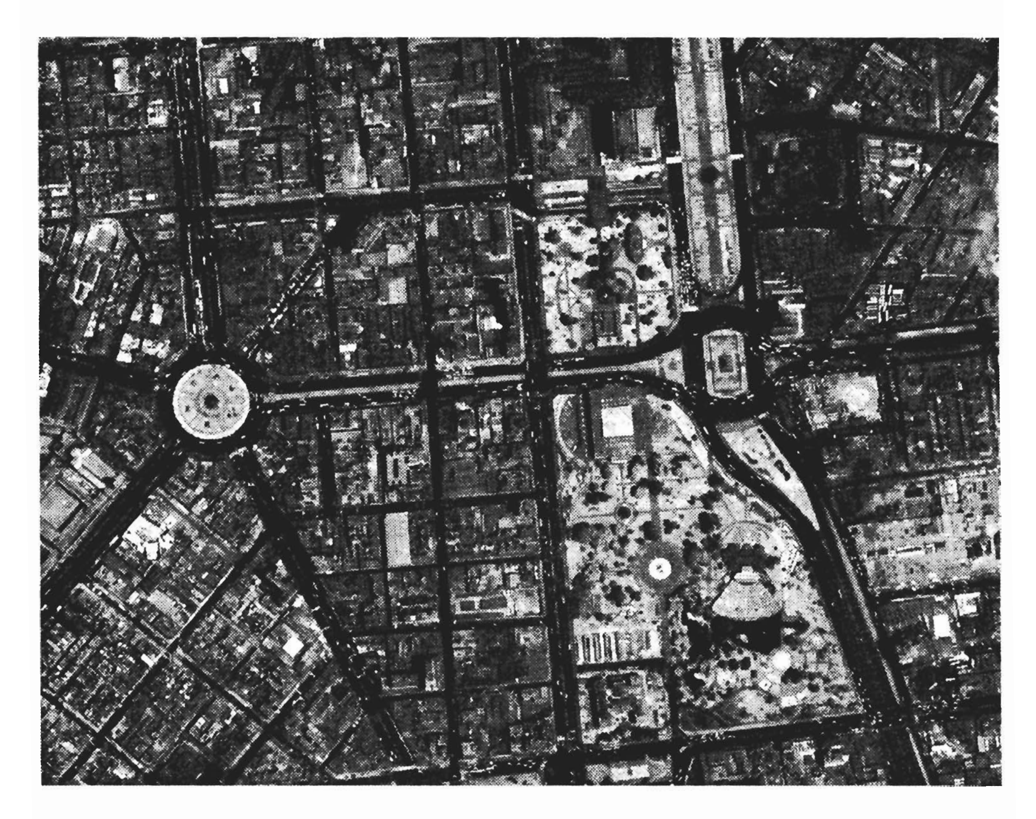


FIG. 1.5. *Imagen pancromática del Quickbird sobre la ciudad de Lima correspondiente al 17 de diciembre de 2001, pocas semanas después del lanzamiento.* (Cortesía: *DigitalGlobe*.)

espacial, facilitada por el propio desarrollo de los Sistemas de Información Geográfica (SIG) y la generosa política de acceso gratuito a los datos. Para el caso concreto de los datos de teledetección, la comercialización privada del programa Landsat supuso un serio revés a las aplicaciones civiles, ante el elevado aumento de los costes. La situación cambió con la nueva plataforma (Landsat-7), que ofrecía una política de distribución mucho más ventajosa, si bien actualmente tiene serios problemas técnicos (ver 3.5.1).

El mercado de la teledetección espacial dio un fuerte impulso con el afianzamiento de los satélites comerciales, que están explorando vías de negocio antes inaccesibles a la observación espacial (O'Connell y Lachman, 2001). Actualmente están disponibles el Ikonos, gestionado por *Space Imaging* que se lanzó en 1999; EROS A1, propiedad de *ImageSat International*, lanzado en 2000, y Quickbird (fig. 1.5), lanzado en octubre de 2001 por la empresa *Digital Globe*. Estos satélites comerciales ya están reemplazando actividades realizadas hasta ahora mediante sensores aeroportados, especialmente a partir de la fotografía aérea convencional, aunque persisten algunos problemas de continuidad y disponibilidad de datos. Además de estas empresas, otras 10 han solicitado al gobierno norteamericano autorización para desarrollar constelaciones comerciales de teledetección (O'Connell y Hilgenberg, 2001, p. 147).

En Canadá la situación también es muy favorable, contando con una institución nacional, el *Canada Center for Remote Sensing*, que cuenta con diversos centros regionales y coordina la actividad docente e investigadora en teledetección. También en este país ejerce su actividad una sociedad profesional, la *Canadian Remote Sensing Society*, dedicada a la organización de congresos periódicos y la publicación de una interesante revista, *Canadian Journal of Remote Sensing*. El lanzamiento de los satélites de la serie Radarsat ha contribuido notablemente al afianzamiento industrial de esta técnica y a la apertura de nuevas aplicaciones.

En el contexto europeo, Reino Unido y Francia han sido los países que se han involucrado más en la investigación aplicada en esta técnica. En cuanto al primero, ya a inicios de los ochenta, podían citarse hasta cincuenta instituciones que trabajaban activamente sobre ella (Bullard y Dixon-Gough, 1985), con una producción bibliográfica muy significativa: varios manuales universitarios, diversas publicaciones científicas (*International Journal of Remote Sensing*, *NRSC Newsletter*), y una sociedad, la *Remote Sensing Society*, muy activa en tareas de enseñanza y difusión. Esta asociación, actualmente denominada *Remote Sensing and Photogrammetry Society* organiza anualmente, desde 1974, un congreso en distintas universidades inglesas. En lo que a diseño de satélites se refiere, conviene citar la actividad de la empresa *Surrey Satellite Technology* Ltd., dedicada a la fabricación de micro-satélites, que ya ha lanzado diversos satélites de bajo coste.

Las autoridades francesas han realizado un gran esfuerzo en este campo, que llevó al lanzamiento del primer satélite SPOT, en 1986, continuado por otros cuatro satélites de la misma serie en 1990, 1993, 1998 y 2002 (ver 3.5.2). El proyecto fue desarrollado por el *Centre National d'Etudes Spatiales* (CNES), con una pequeña colaboración de la *Swedish Space Corporation*. En el terreno de las aplicaciones, el *Groupement pour le Développement de la Télédétection Aérospatiale* (GDTA), con sede en Toulousse, ha realizado numerosos cursos de entrenamiento y ciclos de formación, coordinando a distintas instituciones gubernamentales con interés en teledetección.

Alemania también cuenta con un programa de observación de la Tierra propio, canalizado a través de la Agencia Espacial Alemana DLR. Han enviado varias misiones en el marco de la colaboración con el transbordador espacial norteamericano y la estación espacial orbital, así como algunas misiones específicas orientadas a la detección de incendios (proyecto BIRD). En junio de 2007 lanzaron el primer satélite radar, denominado TerraSAR X, que muy recientemente ha entrado en fase operativa.

Otros países europeos han mostrado gran interés en la aplicación de esta técnica para un mejor conocimiento de sus problemas medioambientales. En los Países Bajos, la actividad docente e investigadora del *Institute for Aerospace Survey and Earth Sciences* (ITC), con sede en Enschede, ha sido muy destacada, tanto en el campo de la docencia como de la investigación (*ITC Journal*). En Bélgica, Italia y los países escandinavos existen numerosos centros dedicados a este tipo de investigaciones. Aunque en los países del Este europeo, la situación todavía es precaria, se están dando pasos hacia una mayor presencia de esta técnica, especialmente en los programas agrícolas y medioambientales.

La Unión Europea (UE), como conjunto, pretende impulsar las aplicaciones de la teledetección mediante una mayor colaboración con la Agencia Espacial Europea (ESA), que ya ha lanzado varios satélites meteorológicos (Meteosat, MSG y Metop) y

tres de recursos naturales (ERS-1 y ERS-2, en 1991 y 1995, respectivamente), y recientemente el Envisat. La colaboración entre la UE y la ESA se traduce en un mayor esfuerzo por utilizar las imágenes de satélite en diversas direcciones generales de la Comisión. Las más activas hasta el momento han sido las dedicadas a Medioambiente y Agricultura. La primera ha promovido la realización del programa *CORINE* para obtener diversas variables de interés ambiental en el conjunto de los países miembros. De entre ellos, el dedicado a la cobertura del suelo (*CORINE-Land Cover*), se desarrolla casi íntegramente a partir de imágenes de satélite, cubriendo no sólo la UE, sino también otros países del este de Europa y norte de África. En cuanto a la Dirección General de Agricultura los programas más consolidados son el inventario de cultivos y la predicción de cosechas. Además, se están realizando trabajos de inventario forestal y de pastizales, así como estudios regionales sobre áreas menos favorecidas. Algunas de estas iniciativas se han canalizado a través del centro común de investigación de la Unión Europea en Ispra (Italia). Este centro ha desarrollado investigación de base y distintas aplicaciones de la teledetección, proporcionando servicios a varias Direcciones Generales de la Comisión. En cuanto a sociedades profesionales, en el ámbito europeo conviene citar la actividad de la Asociación Europea de Laboratorios de Teledetección (*European Association of Remote Sensing Laboratories*, EARSeL), que cuenta con 300 miembros (todos ellos departamentos universitarios o centros de investigación). Organiza congresos anuales y talleres técnicos, publica un boletín de noticias (*EARSeL Newsletter*) y una revista científica basada en los artículos presentados a los distintos talleres (*EARSeL Advances in Remote Sensing*).

El volumen de negocio del mercado europeo de la teledetección se cifró, en un estudio realizado en 1995 en unos 173 millones de euros, afectando a unas 350 organizaciones, con 9.500 empleados (en el estudio no se incluían las industrias dedicadas al desarrollo de los sensores o de las estaciones receptoras). En la mayor parte de los estados las entidades de la Administración resultaban los principales clientes de esta técnica (un 65 %), frente a un 29 % del sector privado y un 6 % de entidades científicas. Las aplicaciones más demandadas eran la cartografía y planeamiento (38 %), agricultura (25 %), sector forestal (13 %) y militar (11 %). Estos datos se han quedado desfasados con las nuevas iniciativas europeas ligadas a la mejora en la observación ambiental y temas de seguridad, englobados en la iniciativa GMES (*Global Monitoring for Enrivonment and Security*), que financia bastantes proyectos en diversas aplicaciones de esta tecnología con ánimo de que puedan convertirse en operativas.

Por no ampliar excesivamente esta relación, podemos concluir citando otros países en donde la teledetección espacial resulta una técnica de notable implantación. Este es el caso de Japón, China, Brasil e India, empeñados en el desarrollo de proyectos espaciales propios, así como de Rusia, con una larga trayectoria en esta disciplina, aunque menos conocida para los países occidentales. Las principales organizaciones son la *National Remote Sensing Agency,* localizada en Hyderabad (India); el *Remote Sensing Technology Center* (RESTEC), situada en Tokio, y el *Instituto Nacional de Pesquisas Espaciais* (INPE), emplazado en São Jose dos Campos (Brasil).

En el ámbito iberoamericano, además del INPE brasileño, también conviene citar la actividad de la CONAE argentina, que ha lanzado varios proyectos propios de observación de la Tierra (SAC-C en 2000). En cuanto a centros universitarios o profesio-

nales comprometidos con esta técnica, cuentan con especial tradición la Universidad Autónoma y el INEGI de México, el Instituto de Geografía cubano, el Centro de Procesamiento Digital de Imágenes en Venezuela, el Instituto Agustín Codazzi en Colombia, la Universidad Católica en Santiago de Chile, el CLIRSEN ecuatoriano y la Universidad de Luján y el INTA argentinos. La Sociedad de Expertos Latinoamericanos en Percepción Remota (SELPER) cuenta actualmente con unos mil miembros organizados en capítulos nacionales, celebra bienalmente un congreso internacional y publica un boletín con noticias y artículos académicos.

Tras repasar el contexto internacional, resulta conveniente detenernos sobre el estado de la teledetección en nuestro país. En ésta, como en otras tecnologías de punta, el desarrollo ha sido paulatino en las últimas décadas, aunque aún no se encuentra plenamente consolidado. Ya en los años setenta se plantearon algunos proyectos de investigación realmente pioneros (Núñez de las Cuevas, 1976), pero la actividad no ha tenido un impulso sostenido hasta épocas recientes. Aunque ha crecido el número y la actividad de los grupos interesados en esta técnica, no se observa todavía un cuerpo científico consolidado, y aún resulta una herramienta con escasa actividad comercial, que sigue dependiendo mucho de las administraciones locales. Ha ganado en los últimos años en presencia en los planes de estudio universitarios, aunque todavía sigue siendo escasa la oferta de programas de especialización. La actividad académica sigue de alguna manera girando en torno a la Asociación Española de Teledetección (AET), creada en 1989 tras cuatro años de actividades como grupo de trabajo. Entre sus logros cuenta la organización de doce congresos nacionales (con periodicidad bienal), y la publicación de una revista científica (la *Revista de Teledetección*) de periodicidad semestral. Todavía el número de afiliados es escaso (no alcanza los trecientos). Otra asociación interesada en esta técnica es la Sociedad Española de Cartografía, Fotogrametría y Teledetección, organizadora de cursos y seminarios esporádicos sobre estas técnicas. A nuestro modo de ver, tal vez una de las principales rémoras para impulsar el desarrollo de la teledetección en España sea la inexistencia de un centro nacional de referencia, similar al NRSC inglés, al ITC holandés o al GDTA francés, que coordine los esfuerzos individuales y ponga en contacto a expertos, empresas y usuarios finales del producto. Los centros más destacados, sin pretender ser exhaustivo, son los dedicados a la producción cartográfica (Instituto Geográfico Nacional, *Institut Cartogràfic de Catalunya*, Agencia de Medioambiente de Andalucía), a la investigación (Instituto Nacional de Técnica Aeroespacial, Instituto Nacional de Investigaciones Agrarias, Instituto Tecnológico y Geominero, Instituto de Economía y Geografía, UAB-CREAF, Instituto de Desarrollo Regional de Albacete), o a la docencia universitaria (Universidad de Alcalá, Granada, Lérida, Las Palmas, Santiago, Valencia y Valladolid). Existe un pequeño número de empresas dedicadas a esta temática (Argongra, Idom, Geosys, Aurensis,...) y otras que cuentan con departamentos de teledetección (Tragsatec, Tracasa, Indra, Insa, Tecnoma). En los últimos años merece especial mención el Plan Nacional de Teledetección, impulsando por el IGN, con apoyo de otras administraciones públicas centrales y regionales, y sobre todo el desarrollo de un programa propio de observación terrestre, formado por dos satélites, Ingenio y Paz, que se prevé estén activos a inicios de la próxima década.

4. Aspectos legales de la teledetección

La teledetección, como ya hemos indicado, supone la observación exterior de la superficie terrestre. El satélite, como es obvio, no ajusta su órbita a las fronteras nacionales, sino que adquiere imágenes de todo el globo. Esta adquisición de datos sobre un territorio soberano puede implicar una violación de su espacio aéreo, además de poner en evidencia información estratégica de un país que podría ser utilizada abusivamente por otro.

Por estas razones, ya desde el inicio de la teledetección se puso de manifiesto la necesidad de regular jurídicamente esas actividades. Las primeras discusiones jurídicas se produjeron a fines de los años cincuenta a propósito de los primeros satélites espía. En 1955 el presidente Eisenhower propuso en una conferencia internacional en Ginebra una política de cielos abiertos (*Open Skies proposal*), que permitiera la observación mutua libre entre las dos potencias, con objeto de que cada una pudiera contar con información real sobre los recursos militares de la otra, reduciendo así las tensiones y la carrera armamentística. Estos vuelos de reconocimiento militar permitirían tender a una mayor confianza mutua entre EE.UU. y la Unión Soviética, relajando las tensiones (Leghorn y Herken, 2001). La propuesta no fue aceptada por el lado soviético, lo que dio lugar a un acelerado desarrollo de los sistemas espaciales de observación militar, no detectables por los métodos convencionales de protección del espacio aéreo. A partir de ahí, se inicio una etapa de aceptación legal tácita de la observación espacial, ya que ambas potencias eran conscientes de que el adversario contaba con los medios para observar su territorio, sin reclamar jurídicamente el fin de esa observación. La situación jurídica de la observación militar se reguló finalmente en 1992, con el tratado de Cielos abiertos (*Open Skies Treaty*), firmado por EE.UU., Canadá y otros estados de la OTAN, por un lado, y varios países del pacto de Varsovia, por otro, incluyendo Rusia, Ucrania y Belarus. El acuerdo permite sobrevolar el territorio de otro estado utilizando sensores específicamente aprobados por el tratado (se van negociando entre las partes), con limitaciones de resolución espacial que varían con la tecnología empleada (Heric *et al.*, 1996). La caída del muro de Berlín en 1989 evidentemente ha creado un nuevo ambiente para este tipo de actividades, que pueden ser de gran interés en la prevención de riesgos militares.

En cuanto a la teledetección civil, está regulada por el Comité de Naciones Unidas para el Uso Pacífico del Espacio Exterior, que ha intentado desarrollar unos principios legales que salven las tensiones entre Estados observados y observadores. El inicio de este proceso se encuentra en el tratado sobre las actividades de exploración del espacio, firmado en 1967. Allí se señalaba que «...el espacio exterior, incluso la Luna y otros cuerpos celestes, no podrá ser objeto de apropiación internacional por reivindicación de soberanía, uso u ocupación, ni mediante ningún otro medio». (*Treaty on principles goberning the activities of States in the exploration and use of outer space, including the Moon and celestial bodies*, art. II.)

Este acuerdo constituye el eje sobre el que se ha venido apoyando el derecho espacial en los últimos años. Sus principales definiciones consagran un doble principio: libertad de exploración y uso del espacio exterior, y empleo en provecho común, sin posibilidad de apropiación por ningún Estado. En definitiva, se define el espacio exterior como un patrimonio común de la Humanidad, no sujeto a intereses nacionales.

En el congreso UNISPACE'82, celebrado en Viena, se expresó el deseo de algunos países en desarrollo por controlar la distribución de las imágenes obtenidas sobre su territorio. Además, se convino en facilitar el acceso inmediato y no restrictivo a la información detectada sobre el territorio perteneciente a cada Estado, así como en solicitar la previa autorización de éste para difundir dicha información a terceros países. Estos principios se plasmaron en la resolución 41/65 de la ONU (diciembre de 1986), que también subraya el interés de esta técnica para promover la protección del medioambiente y la mitigación de catástrofes naturales. Las grandes directrices de esta legislación pueden resumirse en los siguientes puntos (Tapia, 1989):

1. la teledetección se realizará en provecho e interés de todos los países, de acuerdo con el derecho internacional;
2. se respetará el principio de soberanía plena y permanente de los Estados sobre su propia riqueza y recursos naturales, sin perjudicar los legítimos derechos e intereses del Estado observado;
3. se promoverá la cooperación internacional sobre recepción, interpretación y archivo de datos, prestándose asistencia técnica;
4. deberán los Estados informar al Secretario General de las Naciones Unidas de los programas de teledetección que se propongan desarrollar, así como a los Estados interesados que lo soliciten;
5. se informará a los Estados afectados para prevenir fenómenos perjudiciales para su medio ambiente, y contarán con acceso sin discriminación, y a un coste razonable, de los datos obtenidos sobre su territorio.

Estas líneas parecen marcar la evolución reciente del derecho espacial en lo que afecta a actividades de teledetección. La ampliación de estas actividades a otros países más allá de EE.UU. y la Unión Soviética (caso de Japón, Canadá, India o Brasil), y el creciente papel de los consorcios comerciales tiende a liberalizar aún más las disposiciones adquiridas, si bien no resultan todavía muy eficientes los mecanismos de transferencia tecnológica hacia terceros países, casi siempre los más necesitados de una información tan valiosa sobre sus propios recursos naturales. De hecho en la Tercera Conferencia de la ONU sobre los usos pacíficos del espacio exterior (UNISPACE III) celebrada en Viena en 1999, se volvió a subrayar la preocupación de algunos gobiernos sobre la información que facilitan los satélites civiles sobre su territorio (singularmente India e Israel), si bien la principal preocupación de los países en desarrollo era conseguir reducir los costes de las imágenes, en lugar de aumentar los controles sobre su disponibilidad (Florini y Dehqanzada, 2001).

5. Las ventajas de la observación espacial

La teledetección desde satélite cuenta con numerosas aplicaciones, gracias a las ventajas que ofrece frente a otros medios de observación más convencionales, como la fotografía aérea o los trabajos de campo, aunque más que sustituirlos los complementa adecuadamente. Entre las ventajas de esta observación espacial, podemos destacar las siguientes:

5.1. Cobertura global y exhaustiva de la superficie terrestre

La teledetección espacial es una de las pocas fuentes de información propiamente globales, ya que los sistemas orbitales permiten tomar información de la práctica totalidad del planeta, en condiciones comparables (mismo sensor, similar altura). Esta dimensión global resulta de enorme trascendencia para entender los grandes procesos que afectan al medio ambiente de la Tierra (Foody y Curran, 1994). Fenómenos que preocupan notablemente a la comunidad científica, y aun al hombre de la calle, como el deterioro de la capa de ozono (fig. 1.6), el calentamiento de la Tierra o los procesos de desertización, sólo pueden ser entendidos bajo una consideración global —el planeta en su conjunto—, para lo que necesitamos un sistema de información que abarque grandes espacios (Chuvieco, 2008*a*). Es bien conocida la dificultad para establecer bases de datos globales, ya que resulta preciso integrar información proveniente de fuentes nacionales muy diversas, que frecuentemente están compiladas con criterios (desagregación, escalas, etc.) casi incompatibles (Chuvieco, 1992; Unninayar, 1988). Además, en muchas ocasiones estos datos de partida se refieren a localizaciones puntuales (estaciones meteorológicas o de aforo) por lo que es preciso aplicar posteriormente algoritmos de interpolación para obtener una imagen completa del territorio.

La teledetección espacial nos ofrece, por el contrario, una fuente homogénea (el mismo sensor y plataforma para todos los países) y exhaustiva (cubre todo el territorio) de datos para todo el planeta, lo que permite su fácil inclusión en estudios globales. En los años noventa, el programa internacional para el estudio de la geosfera y la biosfera (IGBP), promovió el desarrollo de algunas bases de datos globales a partir de imágenes de satélite, como el mapa mundial de la cobertura del suelo (IGBP-Land Cover: Brown *et al.*, 1993; Townshend *et al.*, 1991), que posteriormente se han actualizado en el marco del programa MODIS y VEGETATION (Lambin y Geist, 2006).

5.2. Perspectiva panorámica

La altura orbital del satélite le permite detectar grandes espacios, proporcionando una visión amplia de los hechos geográficos. Una fotografía aérea, escala 1:18.000 capta en una sola imagen una superficie aproximada de 16 km², que asciende a unos 49 km² en el caso de fotografías a mayor altitud (escala 1:30.000). Una imagen del sensor Landsat-TM nos permite contemplar 34.000 km² en una sola adquisición, llegándose hasta varios millones de kilómetros cuadrados los abarcados por una sola imagen del satélite meteorológico NOAA. Determinados fenómenos de gran radio de cobertura se pueden delimitar a partir de estas imágenes, siendo de difícil percepción para perspectivas más locales. El abombamiento de la Meseta española, por ejemplo, fue detectado a partir de las primeras imágenes Landsat que se obtuvieron de nuestro país (Alía *et al.*, 1976), corrigiendo en parte la visión tradicional que se tenía de esta unidad del relieve. Sobre imágenes de satélite resulta más asequible la detección de algunas fallas, fracturas o contactos litológicos, lo que puede guiar en la localización de algunos recursos minerales (Short y Blair, 1986).

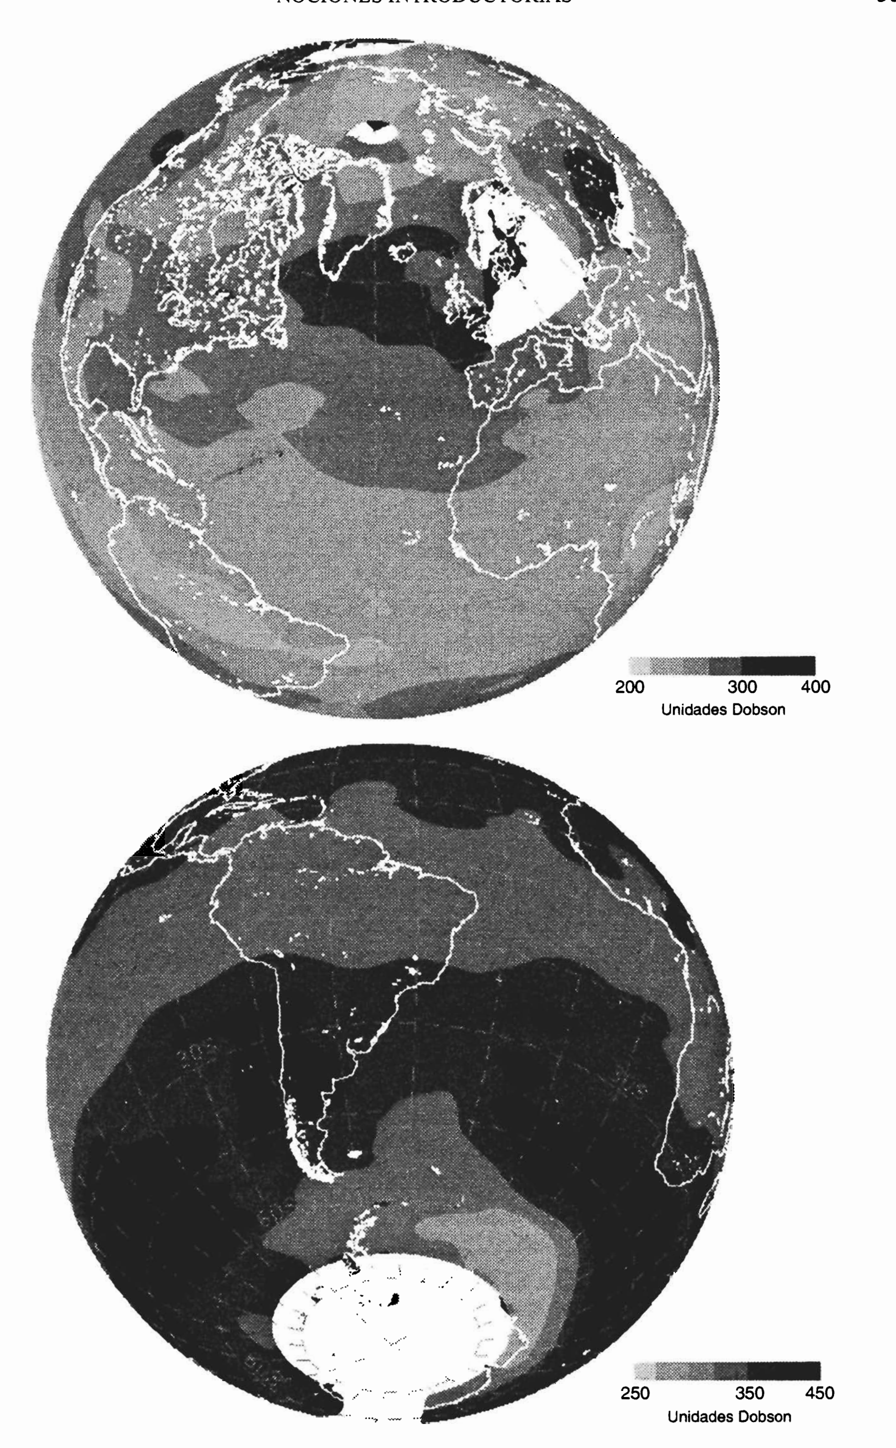


FIG. 1.6. *Estimación del espesor de la capa de ozono a partir de la senda TOMS para el 18 de agosto de 2001.* (FUENTE: DLR).

5.3. Observación multiescala y no destructiva

Como veremos a lo largo de esta obra, los sistemas actuales de teledetección desde satélite ofrecen un amplio rango de cobertura espacial y nivel de detalle, desde los sensores de ámbito local (con resoluciones en torno a 1 m^2 y cobertura en el rango de pocos cientos de km^2), hasta los de ámbito global (con resoluciones de 1 a 5 km^2, pero que abarcan en cada imagen varios millones de km^2). Puesto que las variables físicas que obtienen del suelo son equiparables entre sistemas (reflectividad, temperatura...), si consiguiéramos relacionar estas distintas escalas entre sí, y esas variables, nuestro parámetro de interés (p. ej., clorofila en el agua o rendimiento del cultivo), podríamos utilizar las imágenes para extender las observaciones locales a ámbitos de estimación mucho más amplios. Por ejemplo, podríamos utilizar imágenes para extrapolar cálculos extraídos de un muestreo de temperatura o clorofila en el agua, índices de área foliar, rendimientos del cultivo o humedad de la vegetación (Yebra *et al.*, 2008). Esta capacidad de extrapolar espacialmente las observaciones puntuales tiene gran importancia en el análisis de diversos fenómenos ambientales, ya que las relaciones entre variables pueden cambiar al modificarse la escala (Ehleringer y Field, 1993). Además, conviene subrayar que esta observación no altera las propiedades de la cubierta, lo que permite que sea consistente en el tiempo. No ocurre lo mismo con otros métodos de observación ambiental, que habitualmente requieren muestreos destructivos para poder medir una determinada variable (clorofila, agua, biomasa).

5.4. Información sobre regiones no visibles del espectro

Los sensores ópticos-electrónicos facilitan imágenes sobre tipos de energía que no son accesibles al ojo humano o a la fotografía convencional, como es el caso del infrarrojo medio y térmico o las microondas. Estas bandas del espectro proporcionan una valiosa información para estudios medioambientales. Por ejemplo, el infrarrojo térmico nos permite estudiar la distribución espacial de las temperaturas, con mayor detalle sobre la superficie marina gracias a la homogeneidad de su composición (López, 1991). El seguimiento de corrientes marinas, la detección de surgencias o focos anómalos de calor son buenos ejemplos del interés de este tipo de información, que tienen gran interés en las aplicaciones climáticas o pesqueras (Barreto, 2000). Por otra parte, el infrarrojo medio también resulta de gran interés para la detección de focos de altas temperaturas, como es el caso de los incendios forestales, que pueden delimitarse con bastante precisión (Martín *et al.*, 1999).

5.5. Cobertura repetitiva

Las características orbitales de los satélites de observación terrestre les permiten adquirir imágenes repetitivas de toda la Tierra, en condiciones comparables de observación, lo que resulta idóneo para abordar estudios multitemporales (fig. 1.7). Aunque más tarde veremos con detalle el interés de este análisis multitemporal (cap. 7.3), pueden aquí citarse algunos ejemplos de las posibilidades ofrecidas por esta observación

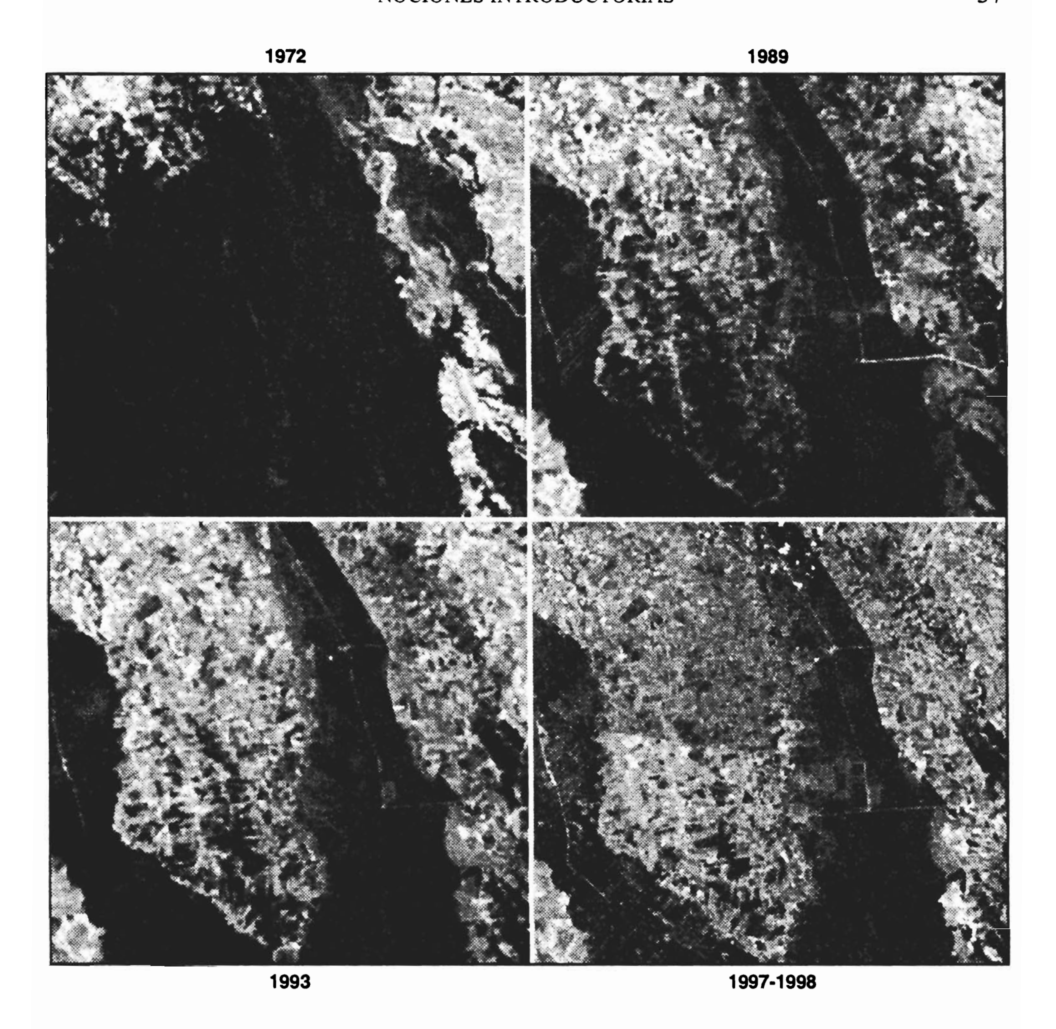


FIG. 1.7. *Avance de la deforestación en la reserva de Ticoporo (Venezuela)* (FUENTE: Franklin, 2000).

periódica: observación de procesos de desertificación (Tucker *et al.*, 1994), análisis de inundaciones, la predicción de la escorrentía en coberturas de nieve (Ferris y Congalton, 1989), el seguimiento de la deforestación (Nelson, 1994), y, por supuesto, la dinámica de los fenómenos meteorológicos (Conway, 1997).

5.6. TRANSMISIÓN INMEDIATA

La mayor parte de los sistemas de teledetección graban las imágenes en formato digital, lo que permite transmitirlas a las estaciones terrestres en tiempo real. En situaciones de emergencia, esta disponibilidad inmediata puede resultar vital, por lo

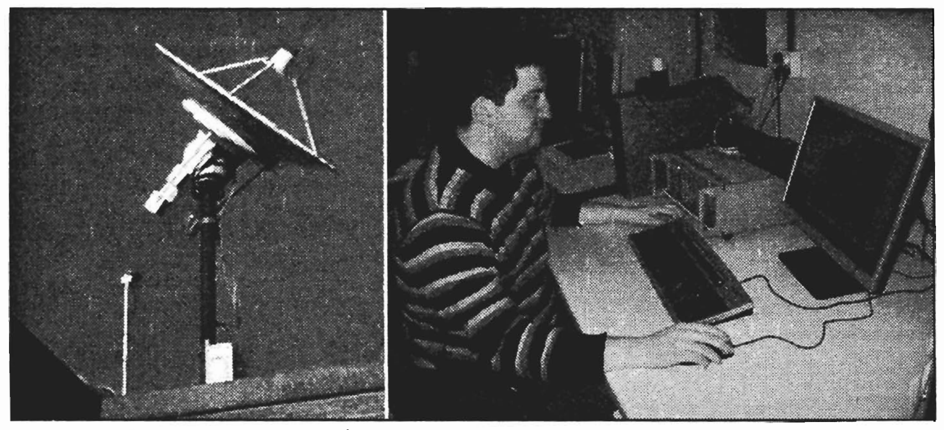


FIG. 1.8. *Sistema de recepción de imágenes NOAA HRPT instalado en el departamento de Geografía de la Universidad de Alcalá.*

que se considera una de las características más destacadas de la teledetección en la gestión de catástrofes (Scott, 1997). En la práctica, sólo los satélites de escala más global ofrecen transmisión directa al usuario final, siempre que se disponga de las antenas receptoras adecuadas (fig. 1.8). El resto de los sistemas se reciben en tiempo real únicamente por la red de estaciones concertadas con la entidad propietaria del satélite, siempre que éste se encuentre en el área de grabación de alguna antena, o de lo contrario se graban a bordo para su transmisión posterior. El usuario recibe las imágenes con un cierto desfase temporal, que se dedica a la calibración de los datos y el envío. La mayor utilización de internet en la difusión de datos está acortando esos plazos, haciendo también posible el empleo casi inmediato de las imágenes de alta resolución espacial.

5.7. FORMATO DIGITAL

Como se comentó más arriba, el tratamiento digital de las imágenes agiliza el proceso de interpretación, permite generar modelos cuantitativos e integrar los resultados con otro tipo de información geográfica. Este enfoque integrado facilita una evaluación más real del paisaje, al considerar los principales elementos espaciales que lo conforman. Aun simplemente en el terreno de la visualización, el apoyo de los ordenadores permite observar el territorio con una precisión y plasticidad difícilmente abordable por otros medios. Este es el caso de las perspectivas tridimensionales, que combinan una imagen de satélite con un modelo topográfico digital. El terreno puede así observarse desde distintos ángulos (fig. 1.9), de cara a diseñar trayectorias virtuales, o simular los efectos de distintas actuaciones sobre el territorio antes de que se produzcan, evitando así pérdidas irreparables.

Esta relación de las ventajas que proporciona esta técnica no implica, naturalmente, que consideremos a la teledetección espacial como una panacea para detectar

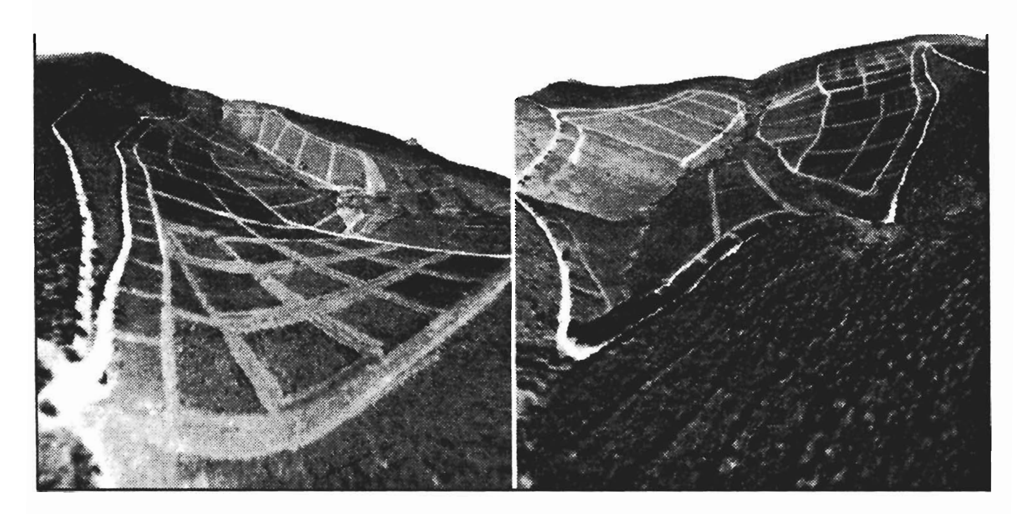


FIG. 1.9. *Diversas perspectivas tridimensionales sobre el área de Gestosa en Portugal, generadas a partir de datos lidar y ortofotografía.*

cualquier problema que afecte al medio ambiente. También presenta diversas limitaciones. La más importante es que la teledetección sólo permite estimar aquellas variables que modifiquen el modo en que una cubierta refleja o emite energía, o —en algunos sistemas— la posición de los objetos. En caso de que el fenómeno de interés no tenga, en consecuencia, un impacto sobre las características espectrales de la zona observada, no podrá detectarse mediante teledetección. Por ejemplo, no pueden discriminarse sobre una imagen de satélite variables que se desarrollan en profundidad (como el perfil de un suelo) o las que se refieren al uso del territorio, siempre que no implique un cambio de cobertura: un gran centro comercial sí implica un cambio de ocupación del suelo, pero no el uso comercial minorista, habitualmente situado en el mismo edificio —y por tanto, con la misma cubierta— que un uso residencial en altura.

Relacionada con esta restricción estaría el hecho de que la mayor parte de los sensores de teledetección sólo captan las características más superficiales de una cubierta. Habitualmente no tenemos información de las capas más profundas, tanto del agua como del suelo, y la observación se limita a lo que ocurre en los primeros centímetros o metros, dependiendo de las propiedades de la cubierta. En el caso de la vegetación sí puede extraerse información sobre capas inferiores, hasta una determinada cantidad de capas, pero con menor sensibilidad según nos alejamos de la más externa.

Otras limitaciones son derivadas del propio desarrollo de la tecnología, que supongan restricciones en la resolución espacial, espectral o temporal disponible, y que pueden no ser suficientes para resolver un cierto problema. Por ejemplo, los estudios de morfología urbana hasta la llegada de los satélites comerciales de alta resolución estaban seriamente limitados, y todavía hay muchas otras aplicaciones que no son factibles con la resolución de los sistemas actuales. Además, la cobertura de nubes puede reducir notablemente en algunas zonas la frecuencia temporal proporcionada por estos sistemas espaciales, restringiéndose la observación de esas áreas a la proporcionada por los sistemas de radar (3.4.1).

Es obvio, en definitiva, que esta observación es complementaria con otras técnicas convencionales y que no invalida la importancia del trabajo de campo. En otras palabras, es una técnica auxiliar más, idónea en múltiples contextos y discreta en otros, en los que su aplicación resulta sólo un ensayo experimental.

6. **Fuentes bibliográficas**

Como antes se indicó la teledetección es una técnica bastante reciente, pese a lo cual la producción bibliográfica resulta ya considerable. En el panorama internacional, se cuenta con numerosos congresos, revistas especializadas, manuales e informes de investigación centrados en esta tecnología. Esto explica la existencia de diversos catálogos bibliográficos, y de varias series periódicas dedicadas a la recopilación de literatura científica en este campo. Actualmente los buscadores de internet son las fuentes más utilizadas para la búsqueda de información, si bien están poco estructurados a veces, y resulta complejo extraer las más relevantes.

En el capítulo de revistas especializadas, se cuentan *Canadian Journal of Remote Sensing, Geocarto International, IEEE Transactions on Geoscience and Remote Sensing, International Journal of Remote Sensing, Photogrammetria, Photogrammetric Engineering and Remote Sensing, Remote Sensing of Environment, Remote Sensing Reviews y ISPRS Journal of Photogrammetry and Remote Sensing*. De ellas, las de mayor impacto (de acuerdo al *Science Citation Index*) son *Remote Sensing of Environment, IEEE Transactions on Geoscience and Remote Sensing, International Journal of Remote Sensing* y *Photogrammetric Engineering and Remote Sensing*. En el ámbito de habla hispana, conviene citar la *Revista de Teledetección*, que se publica semestralmente desde 1993, el boletín de la SELPER, y la revista *Geo-focus*, publicada exclusivamente en versión electrónica.

Los Congresos más destacados son los que organizan las sociedades profesionales: *International Society for Photogrammetry and Remote Sensing* (ISPRS), *American Society of Photogrammetry and Remote Sensing* (ASPRS), *International Geoscience and Remote Sensing Society* (IGARS), *Remote Sensing and Photogrammetry Society* (RSPS), y *European Association of Remote Sensing Laboratories* (EARSeL). Tienen también gran prestigio la serie de congresos denominados *International Symposium on Remote Sensing of Environment*, organizados por el ERIM, y los *Pecora Symposium*, también de la ASPRS, aunque centrados únicamente en aplicaciones medioambientales.

En cuanto a manuales de estudio, buena muestra del grado de desarrollo alcanzado por esta técnica es la amplia gama de textos disponibles, una buena parte de ellos de reciente publicación o reedición (Allan, 1983; Asrar, 1989; Barret y Curtis, 1999*a*; Carter, 1986; Conway, 1997; Cracknell y Hayes, 1991; Curran, 1985; Drury, 1998; Elachi, 1987; Franklin, 2001; Gibson y Power, 2000*b*; Gibson y Power, 2000*a*; Harper, 1983; Harris, 1987; Hobbs y Mooney, 1990; Holz, 1973; Hord, 1986; Jensen, 1996; Jensen, 2000; Kramer, 2002; Liang, 2004; Lillesand y Kiefer, 2000; Lo, 1986; McCloy, 1995; Morain y Budge, 1996; Muller, 1988*a*; Pinilla, 1995; Quattrochi y Goodchild, 1997; Rees, 1999; Richards y Xia, 1999; Ruiz, 1994; Schowengerdt, 1997; Short, 2006; Sobrino, 2000; Swain y Davis, 1978; Szekielda, 1988; Thomas

et al., 1987*a*; Verbyla, 1995). También se han publicado varios libros temáticos, centrándose en la aplicación de la teledetección al ámbito urbano (Au, 1993; Lulla, 1993), edafología y geología (Drury, 1998; Mulders, 1987; Rencz y Ryerson, 1999; Short y Blair, 1986), hidrología (Gower, 1994; Hall y Martinec, 1985; Robinson, 1985), climatología (Barret, 1974; Carleton, 1991; Conway, 1997), ecología del paisaje (Frohn, 1998), vegetación (Franklin, 2001; Hobbs y Mooney, 1990; Howard, 1991), incendios forestales (Ahern *et al.*, 2001; Chuvieco, 1999*a*; Chuvieco, 2003), usos del suelo (Lambin y Geist, 2006) o cambio global (Chuvieco, 2008*a*)

Para cuestiones didácticas resultan también de gran interés los catálogos y atlas de imágenes de satélite, que recogen abundantes ejemplos de imágenes sobre un determinado territorio o área temática de interés. Entre las obras más interesantes se cuentan: *Mission to Earth: Landsat views of the World* (NASA, 1976), *Earth Watch* (Sheffield, 1981) y *Man on Earth* (Sheffield, 1983). Las tres están basadas exclusivamente sobre imágenes Landsat, mientras *Images of Earth* (Francis y Jones, 1984) incluye algunas fotografías tomadas desde el transbordador espacial norteamericano. Con un criterio más cartográfico, destaca la obra de la casa alemana Westerman, traducida posteriormente al inglés (Smith, 1984), así como la cobertura de imágenes del Reino Unido (Bullard y Dixon-Gough, 1985), de Venezuela (Ruiz, 1992), magníficamente cuidado, de Siria (GORS, 1996), y de algunas regiones españolas (Moreira y Ojeda, 1992; Sancho, 1992; Sancho y Chuvieco, 1986), y de paisajes de Iberoamérica (Sancho y Chuvieco, 1992), que presentan numerosos ejemplos de análisis ambiental sobre las imágenes. También con un enfoque cartográfico conviene citar la obra de varios autores del Este europeo (Sagdejew, 1982), con la novedad de que incorporaron fotografías adquiridas por plataformas soviéticas, poco accesibles hasta hace unos años en los países occidentales. Finalmente, los trabajos de la Institución *Smithsonian* (Strain y Engle, 1993), de la Sociedad Audobon (*National Audubon Society*, 1995), y de la *National Geographic Society* (*National Geographic*, 1999) abarcan un amplio abanico de sensores y países. Sin duda, el más destacado en su concepción y presentación es el último, con magníficos ejemplos de imágenes procedentes de distintas misiones espaciales. En otro orden de cosas, diversas entidades cartográficas publican series de orto-imágenes de distintos sensores (principalmente Landsat-TM), a precios muy asequibles, lo que permiten extender al gran público la familiarización de estas imágenes (Martínez Vega, 1997).

CAPÍTULO 2

PRINCIPIOS FÍSICOS DE LA TELEDETECCIÓN

«Dos excesos: excluir la razón, y no admitir más que la razón.»

BLAISE PASCAL, *Pensamientos*

En el capítulo anterior se presentaban algunos aspectos introductorios de las técnicas analizadas en esta obra. En los dos próximos, se van a exponer los procesos que permiten la adquisición de la imagen, para dedicar el resto a las tareas de interpretación. Para los científicos con preocupación por el medio ambiente, lo habitual será que estos últimos sean los que merezcan una mayor atención. Sin embargo, como es obvio, la interpretación de la imagen será tanto más rigurosa cuanto mayor conocimiento se tenga de los procesos que permitieron adquirirla.

1. **Fundamentos de la observación remota**

Anteriormente se definió la teledetección como aquella técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. Para que esta observación remota sea posible, es preciso que entre los objetos y el sensor exista algún tipo de interacción. Nuestros sentidos perciben un objeto sólo cuando pueden descifrar la información que éste les envía. Por ejemplo, somos capaces de ver un árbol porque nuestros ojos reciben y traducen convenientemente una energía luminosa procedente del mismo. Esa señal, además, no es originada por el árbol, sino por un foco energético exterior que le ilumina. De ahí que no seamos capaces de percibir ese árbol en plena oscuridad.

Este sencillo ejemplo nos sirve para introducir los tres principales elementos de cualquier sistema de teledetección: sensor (nuestro ojo), objeto observado (árbol) y flujo energético que los pone en relación y permite, en última instancia, detectar el objeto. En nuestro ejemplo, ese flujo procede del árbol por reflexión de la luz solar. Podría también tratarse de un tipo de energía emitida por el propio objeto (en caso de que fuéramos capaces de detectar el calor que emite), o incluso por el sensor (por ejemplo, si tuviéramos una cámara equipada con *flash*). Éstas son, precisamente, las tres formas

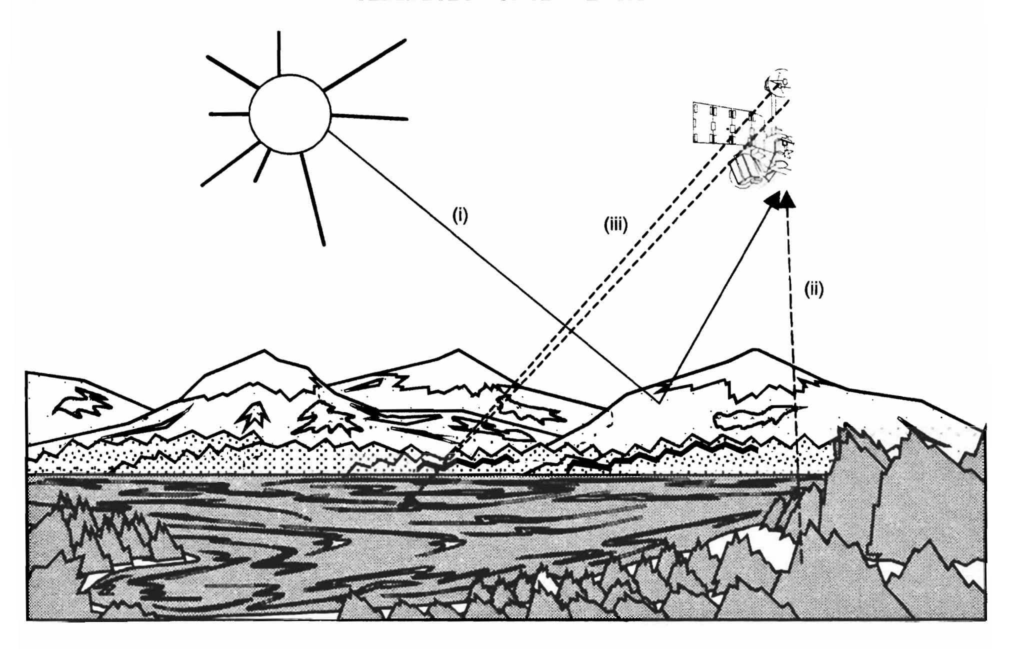


FIG. 2.1. *Formas de teledetección: (i) reflexión; (ii) emisión; (iii) reflexión-emisión.*

de adquirir información a partir de un sensor remoto: por reflexión, por emisión y por emisión-reflexión (fig. 2.1).

La primera de ellas es la forma más importante de teledetección, pues se deriva directamente de la luz solar, principal fuente de energía de nuestro planeta. El Sol ilumina la superficie terrestre, que refleja esa energía en función del tipo de cubierta presente sobre ella. Ese flujo reflejado se recoge por el sensor, que lo transmite posteriormente a las estaciones receptoras. Entre superficie y sensor se interpone la atmósfera, que dispersa y absorbe parte de la señal original. De igual forma, la observación remota puede basarse en la energía emitida por las propias cubiertas, o en la que podríamos enviar desde un sensor que fuera capaz, tanto de generar su propio flujo energético, como de recoger posteriormente su reflexión sobre la superficie terrestre.

En cualquiera de estos casos, el flujo energético entre la cubierta terrestre y el sensor constituye una forma de radiación electro-magnética. Como es sabido, la energía se transfiere de un lugar a otro por tres procesos: convección, conducción y radiación. De ellos, nos centraremos en este último, pues constituye la base de los sistemas de teledetección analizados en esta obra.

Históricamente las propiedades de la radiación electro-magnética se han explicado por dos teorías aparentemente contrapuestas: aquella que la concibe como un haz ondulatorio (Huygens, Maxwell), y aquella otra que la considera como una sucesión de unidades discretas de energía, fotones o cuantos, con masa igual a cero (Planck, Einstein). Las dos teorías se pueden compaginar, pues se ha demostrado que la luz presenta comportamientos que pueden explicarse de acuerdo a ambos planteamientos.

Según la teoría ondulatoria, la energía electro-magnética se transmite de un lugar a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y contenien-

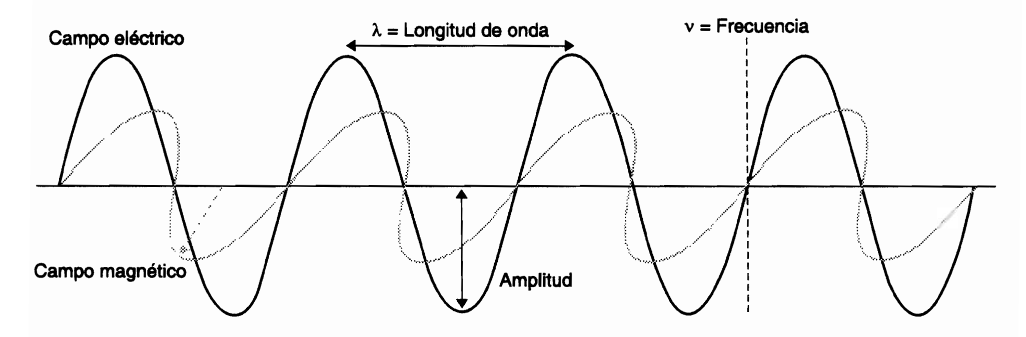


FIG. 2.2. *Esquema de una onda electromagnética.*

do dos campos de fuerzas ortogonales entre sí: eléctrico y magnético (fig. 2.2). Las características de este flujo energético pueden describirse por dos elementos: longitud de onda (λ) y frecuencia (ν). La primera hace referencia a la distancia entre dos picos sucesivos de una onda, mientras que la frecuencia designa el número de ciclos pasando por un punto fijo en una unidad de tiempo. Ambos elementos están inversamente relacionados:

$$c = \lambda \nu \qquad \{2.1\}$$

donde c indica la velocidad de la luz (3×10^8 m s^{-1}), λ expresa la longitud de onda (en unidades de longitud, habitualmente micrómetros, 1 μm = 10^{-6} m o nanómetros, 1 nm = 10^{-9} m) y ν la frecuencia (en Hertz, 1 Hz = 1 ciclo por segundo). En definitiva, a mayor longitud de onda, menor frecuencia y viceversa, por lo que basta con indicar un solo término para caracterizar el flujo de energía mencionado.

Gracias a la teoría cuántica, podemos calcular la cantidad de energía transportada por un fotón, siempre que se conozca su frecuencia:

$$Q = h \nu \qquad \{2.2\}$$

donde Q es la energía radiante de un fotón (en julios), ν la frecuencia y h la constante de Planck ($6{,}6 \times 10^{-34}$ J s). Sustituyendo en {2.1}, podemos asimismo expresar:

$$Q = h\,(c/\lambda) \qquad \{2.3\}$$

lo que significa, en definitiva, que a mayor longitud de onda —o menor frecuencia— el contenido energético será menor y viceversa. Esto implica que la radiación en longitudes de onda largas es más difícil de detectar que aquélla proveniente de longitudes cortas, de ahí que las primeras requieran medios de detección más refinados.

2. El espectro electromagnético

De las fórmulas anteriores, se deduce que podemos definir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia. Aunque la sucesión de va-

lores de longitud de onda es continua, suelen establecerse una serie de bandas en donde la radiación electro-magnética manifiesta un comportamiento similar. La organización de estas bandas de longitudes de onda o frecuencia se denomina espectro electro-magnético (fig. 2.3). Comprende desde las longitudes de onda más cortas (rayos gamma, rayos X), hasta las kilométricas (tele-comunicaciones). Las unidades de medida más comunes se relacionan con la longitud de onda. Para las más cortas se utilizan micrómetros, mientras las más largas se miden en centímetros o metros. Normalmente a estas últimas (denominadas micro-ondas) se las designa también por valores de frecuencia (en Gigahertz, GHz = 10^9 Hz).

Desde el punto de vista de la teledetección, conviene destacar una serie de bandas espectrales, que son las más frecuentemente empleadas con la tecnología actual. Su denominación y amplitud varían según distintos autores, si bien la terminología más común es la siguiente:

— *Espectro visible (0,4 a 0,7 μm).* Se denomina así por tratarse de la única radiación electro-magnética que pueden percibir nuestros ojos, coincidiendo con las longitudes de onda en donde es máxima la radiación solar. Dentro de esta región, suelen distinguirse tres bandas elementales, que se denominan azul (A: 0,4- 0,5 μm), verde (V: 0,5-0,6 μm), y rojo (R: 0,6-0,7 μm), en razón de los colores primarios que nuestros ojos perciben a esas longitudes de onda.

— *Infrarrojo cercano (IRC: 0,7 a 1,3 μm).* También se denomina infrarrojo próximo, reflejado o fotográfico, puesto que parte de él puede detectarse a partir de películas dotadas de emulsiones especiales. Como veremos luego, resulta de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.

— *Infrarrojo medio (IRM: 1,3 a 8 μm).* En esta región se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre. En el primer caso, hablamos de infrarrojo de onda corta (*Short Wave Infrared*, SWIR), que se sitúa entre 1,3 y 2,5μm y resulta una región idónea para estimar el contenido de humedad en la vegetación o los suelos. La segunda banda de interés está comprendida entre 3 y 5 μm, y suele denominarse más propiamente como infrarrojo medio (IRM), siendo determinante para la detección de focos de alta temperatura (incendios o volcanes activos).

— *Infrarrojo lejano o térmico (IRT: 8 a 14 μm)*, que incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres.

— *Micro-ondas (M, por encima de 1 mm)*, con gran interés por ser un tipo de energía bastante transparente a la cubierta nubosa.

Más adelante se estudiará el comportamiento espectral de las principales cubiertas terrestres en cada una de estas bandas del espectro. Antes de ello, convendrá introducir algunos conceptos y unidades de medida comúnmente empleados en teledetección.

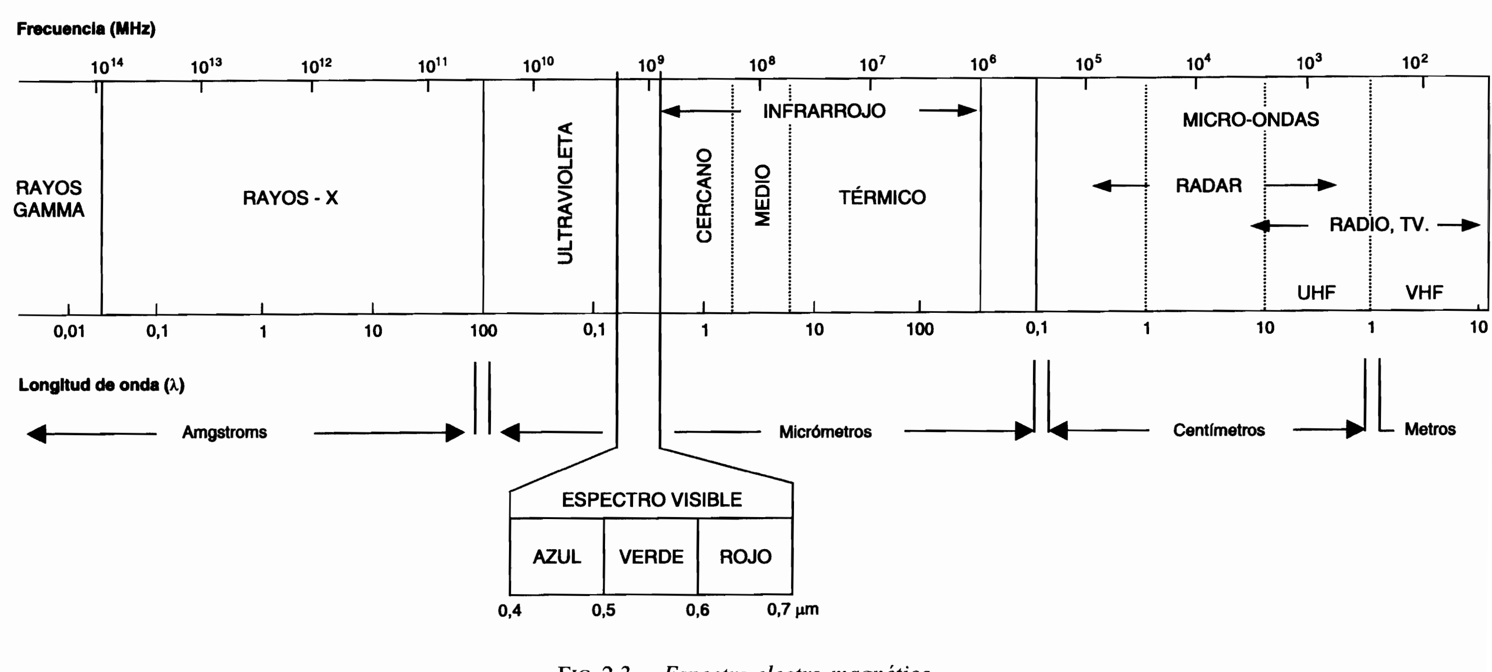


FIG. 2.3. *Espectro electro-magnético.*

3. Términos y unidades de medida

Como más arriba se indicó, para que pueda producirse una observación remota de la superficie terrestre es preciso que el sensor detecte un flujo energético proveniente de ésta. Ese flujo tiene una intensidad determinada, proveniente de, o dirigida a, una unidad de superficie y con una dirección concreta. Convendrá, por tanto, explicitar las unidades de medida más empleadas en teledetección, con objeto de ser rigurosos a la hora de presentar posteriormente los procesos de adquisición. Utilizaremos los sufijos «-ancia» para referirnos a magnitudes absolutas e «-ividad» para referirnos a magnitudes relativas. La formulación precisa de cada una de estas magnitudes se acompaña en la tabla 2.1:

— *Energía radiante (Q).* Indica el total de energía radiada en todas las direcciones. Se mide en julios (J).

— *Flujo radiante (ϕ).* Total de energía radiada en todas las direcciones por unidad de tiempo. Se mide en vatios (W).

— *Emitancia o excitancia radiante (M).* Total de energía radiada en todas las direcciones desde una unidad de área y por unidad de tiempo. Se mide en vatios por metro cuadrado ($W\ m^{-2}$).

— *Irradiancia (E).* Total de energía radiada sobre una unidad de área y por unidad de tiempo. Es equivalente a la emitancia, si bien ésta indica la energía emitida, mientras la irradiancia refiere a la incidente ($W\ m^{-2}$).

— *Intensidad radiante (I).* Total de energía radiada por unidad de tiempo y por ángulo sólido (Ω). Se trata éste de un ángulo tridimensional, que refiere a la sección completa de la energía transmitida, y se mide en estéreo-radianes (fig. 2.4). Por tanto la intensidad radiante se mide en vatios por estéreo-radián ($W\ sr^{-1}$).

TABLA 2.1. *Magnitudes radiométricas comúnmente utilizadas en teledetección*

Concepto	*Símbolo*	*Fórmula*	*Unidad de medida*
Energía radiante	Q	—	Julios (J)
Flujo radiante	ϕ	$\delta Q/dt$	Vatios (W)
Emitancia	M	$\delta\phi/\delta A$	$W\ m^{-2}$
Irradiancia	E	$\delta\phi/\delta A$	$W\ m^{-2}$
Intensidad radiante	I	$\delta\phi/\delta\Omega$	$W\ sr^{-1}$
Radiancia	L	$\delta\phi/\delta A \cos\theta$	$W\ m^{-2}\ sr^{-1}$
Radiancia espectral	L_λ	$\delta L/\delta_\lambda$	$W\ m^{-2}\ sr^{-1}\ \mu m^{-1}$
Emisividad	ε	M/M_n	
Reflectividad	ρ	ϕ_r/ϕ_i	
Absortividad	α	ϕ_a/ϕ_i	
Transmisividad	τ	ϕ_t/ϕ_i	

sr: Estéreo-radián, medida del ángulo sólido.
μm: Micrómetro o micra (10^{-6} metros).
M_n: Emitancia de un cuerpo negro a la misma temperatura.
ϕ_i: Flujo incidente.
ϕ_r: Flujo reflejado.
ϕ_a: Flujo absorbido.
ϕ_τ: Flujo transmitido.
θ: Ángulo formado por el flujo y la dirección normal.

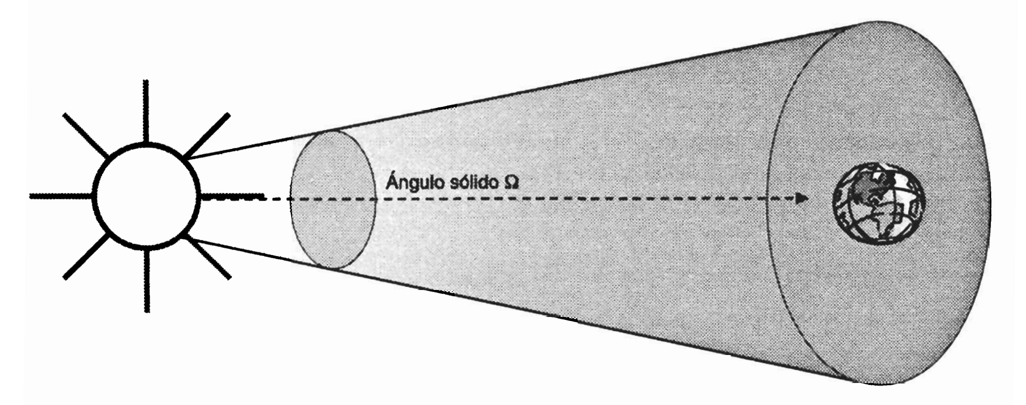


FIG. 2.4. *Esquema del ángulo sólido.*

— *Radiancia (L).* Total de energía radiada en una determinada dirección por unidad de área y por ángulo sólido de medida. Es un término fundamental en teledetección, ya que describe precisamente lo que mide el sensor. Se cuantifica en vatios por metro cuadrado y estéreoradián ($W\ m^{-2}\ sr^{-1}$).

— *Radiancia espectral (L_λ).* Por extensión del concepto anterior, indica el total de energía radiada en una determinada longitud de onda por unidad de área y por ángulo sólido de medida. Por cuanto el sensor detecta una banda particular del espectro, ésta es la medida más cercana a la observación remota. De igual forma que la radiancia, la emitancia e irradiancia pueden completarse con el calificativo de espectral (añadiendo el subíndice λ), cuando se refieren a una determinada longitud de onda.

En cuanto a las magnitudes relativas (adimensionales), las más importantes son:

— *Emisividad (ε),* relación entre la emitancia de una superficie (M), y la que ofrecería un emisor perfecto, denominado cuerpo negro, a la misma temperatura (M_n).

— *Reflectividad (ρ),* relación entre el flujo incidente y el reflejado por una superficie.

— *Absortividad (α),* relación entre el flujo incidente y el que absorbe una superficie.

— *Transmisividad (τ),* relación entre el flujo incidente y el transmitido por una superficie.

Estos últimos términos son también dependientes de la longitud de onda, por lo que conviene completarlas con el calificativo de espectral, para referirse a su valor en una banda determinada del espectro.

4. Principios y leyes de la radiación electromagnética

El objeto de este capítulo es caracterizar espectralmente las distintas cubiertas de interés medioambiental. Para ello, resulta obligado comentar los procesos más impor-

tantes que permiten explicar ese comportamiento, así como los factores que intervienen en su variación. Esta base permitirá abordar una interpretación más rigurosa de la imagen finalmente obtenida por el sensor.[1]

De acuerdo a la fórmula {2.3}, la cantidad de energía que contiene un flujo radiante es inversamente proporcional a su longitud de onda. Esta relación entre flujo de energía y longitud de onda puede establecerse con mayor rigor gracias a la ley de Planck:

$$M_{n,\lambda} = \frac{2\pi hc^2}{\lambda^5 \left\{ \exp \dfrac{hc}{\lambda kT} - 1 \right\}} \qquad \{2.4\}$$

donde $M_{n,\lambda}$ indica la emitancia radiativa espectral de un cuerpo negro a una determinada longitud de onda (λ); h es la constante de Planck ($6{,}626 \times 10^{-34}$ W s^2); k, la constante de Boltzmann ($1{,}38 \times 10^{-23}$ W s^2 K^{-1}); c, la velocidad de la luz; l, la longitud de onda, y T, la temperatura absoluta de un cuerpo negro (en Kelvin, K). Esta fórmula se puede simplificar sustituyendo algunos términos por constantes:

$$M_{n,\lambda} = \frac{c_1}{\lambda^5 \left\{ \exp \dfrac{c_2}{\lambda T} - 1 \right\}} \qquad \{2.5\}$$

donde c_1 puede sustituirse por $3{,}741 \times 10^8$ W $m^{-2}\mu m^4$ y c_2 por $1{,}438 \times 10^4$ µm K.

En pocas palabras, la fórmula de Planck nos señala que cualquier objeto por encima del cero absoluto (–273° C) radia energía, y que ésta aumenta con la temperatura. A la vez, a mayor temperatura, ese cuerpo radiará con más intensidad en longitudes de onda más cortas. De esta fórmula podemos reconstruir la curva de emitancia de un cuerpo negro a distintas temperaturas (fig. 2.5). El gráfico es muy interesante para conocer el comportamiento radiativo de un objeto, siempre que conozcamos su temperatura y su emisividad; esto es, su grado de similitud con un cuerpo negro.

A partir de la fórmula de Planck puede calcularse la longitud de onda a la que se produce la máxima emitancia de un cuerpo negro conociendo su temperatura. Esta es la llamada ley del desplazamiento de Wien:

$$\lambda_{max} = \frac{2.898}{T} \mu m \text{ K} \qquad \{2.6\}$$

donde la temperatura (T) está expresada en Kelvin. Esta ley tiene una gran importancia para seleccionar la banda más conveniente para detectar un objeto a una determinada temperatura. Por ejemplo, si asumimos que un incendio forestal presenta una temperatura de combustión próxima a los 800 K, la ley de Wien nos permite situar en 3,6 µm (IRM) la banda espectral más adecuada para su detección. Por su parte, el Sol

1. El lector interesado en una mayor profundización en estos principios físicos puede consultar otros manuales más especializados como los de Asrar (1989), Slater (1980) o Sobrino (2000).

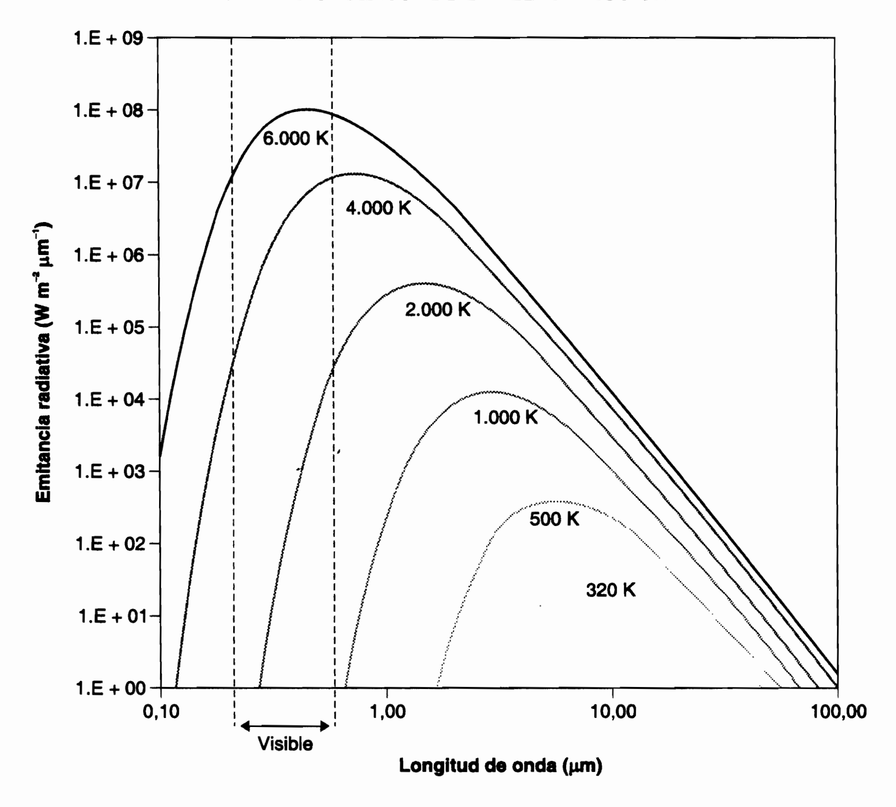


FIG. 2.5. *Emitancia espectral de un cuerpo negro a distintas temperaturas.*

—con una temperatura radiante próxima a los 6.000 K— presenta su máxima emitancia en la región del espectro visible (centrada en torno a 0,5 µm).

Integrando la emitancia espectral de un cuerpo negro para todas las longitudes de onda, podemos calcular el total de energía que radia por unidad de superficie. Esta es la ley de Stefan-Boltzmann:

$$M_n = \sigma T^4 \qquad \{2.7\}$$

donde σ es la constante de Stefan-Boltzmann ($5,67 \times 10^{-8}$ W m^{-2} K^{-4}), y T la temperatura en Kelvin. A consecuencia de esta fórmula, resulta evidente que la emitancia global de un objeto es una función de su temperatura, y que pequeños cambios en ésta suponen notables modificaciones en su emitancia radiante. Por otra parte, conociendo la temperatura de un objeto emisor, podemos también estimar la irradiancia incidente sobre el sensor, por cuanto emitancia e irradiancia son funcionalmente equivalentes. Hasta aquí, hemos supuesto que las superficies naturales se comportan como cuerpos negros, lo que implica una notable simplificación. Por ello, se han de corregir las fórmulas anteriores añadiendo un nuevo parámetro, la emisividad (ε), que nos indica la proporción de energía emitida por un objeto (M) frente a un cuerpo negro a la misma temperatura (M_n):

$$M = \varepsilon M_n \quad \{2.8\}$$

Un cuerpo negro indica un emisor perfecto; esto es, un objeto que absorbe y emite toda la energía que recibe. Se habla de cuerpos blancos o reflectores perfectos, cuando no absorben nada de la energía incidente, sino que la reflejan por completo (emisividad = 0), mientras serían cuerpos grises aquellos objetos que absorben y emiten de forma constante en distintas longitudes de onda. Cuando la emisividad varía con la longitud de onda, se emplea el término de radiador selectivo, que es lo más frecuente en la naturaleza.

A partir de las fórmulas {2.4} a {2.8} podemos estimar la emitancia total y espectral de un objeto conociendo su temperatura absoluta, siendo aquélla tanto mayor cuanto más alta sea ésta. En definitiva, la energía emitida desde un objeto es primariamente una función de su temperatura. Pequeños cambios en ésta suponen una modificación sensible de la emitancia total, de acuerdo a {2.7}. Además, conociendo la temperatura de un objeto o cubierta de interés —y dado que pueda estimarse su emisividad—, será posible determinar la banda del espectro más idónea para su discriminación.

Con estas nociones puede abordarse el comentario más detallado de las tres regiones del espectro en donde se realizan procesos de teledetección: longitudes de onda cortas (desde el visible al SWIR), medias (IRM y térmico) y largas (micro-ondas).

5. **El dominio solar del espectro**

5.1. Características de la radiación solar. Interacción con las cubiertas terrestres

Denominamos espectro solar al rango de longitudes de onda directamente dependientes de la radiación, comprendidas entre el visible y el SWIR (0,4 a 2,5 μm).

Para una mejor comprensión de estas bandas espectrales, conviene analizar con más detenimiento en este apartado las características radiativas del Sol, fuente primordial de energía radiante en nuestro planeta. Más adelante nos detendremos a analizar el comportamiento de las principales coberturas terrestres frente a este tipo de radiación.

El Sol se encuentra a una temperatura radiante próxima a los 6.000 K. Esto implica, según la ley de Wien, que su máxima emitancia espectral se produce en torno a las 0,48 μm, coincidente con el color verde apreciado por nuestros ojos. La curva espectral de la radiación solar se asemeja bastante a la de un cuerpo negro a esa temperatura, tal y como aparece en la figura 2.6. La radiancia solar que al llegar al techo de la atmósfera es inferior a ésta, especialmente a partir de 2,5 μm, donde ya es muy escasa, y empieza a ser dominante la radiación térmica emitida por cuerpos calientes (incendios, volcanes, etc.) a partir de 3 μm y por la superficie terrestre (a partir de 8 μm). Si comparamos la radiancia solar que llega a la atmósfera terrestre con la que esperaríamos para un cuerpo negro a la temperatura radiativa del Sol, se observa que es sensiblemente más baja (fig. 2.6). Esto es debido a que la Tierra sólo capta una pequeña parte de la emitancia solar, en función de su tamaño y de la distancia a la que se encuentra (Markham y Barker, 1987). Además, parte de la radiación solar que llega al te-

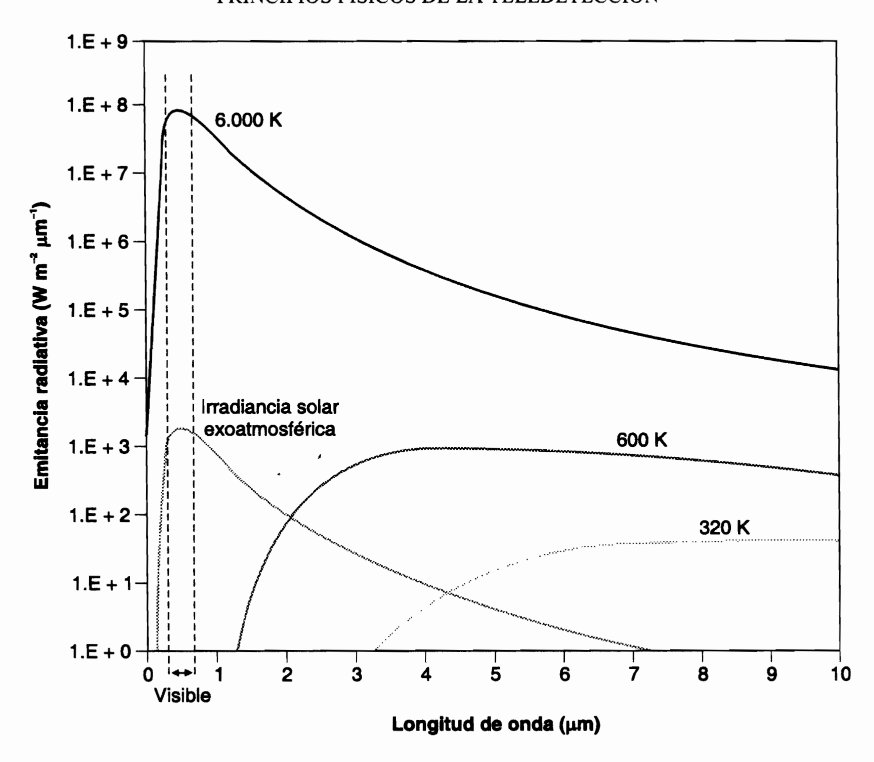


FIG. 2.6. *Comparación entre la emitancia de un cuerpo negro a 6.000 K, la irradiancia solar exo-atmosférica y la emitancia a temperatura terrestre y para un foco de mayor temperatura.*

cho de la atmósfera se filtra por los gases que la forman, con lo que la radiación directa que llega al suelo es bastante menor. Por término medio, llegan a la superficie terrestre unos 1366 W m^{-2}, lo que equivale a unas 1,96 calorías por minuto y centímetro cuadrado. Esa cantidad, que suele denominarse constante solar, incluye el promedio de la radiación solar recibida en las distintas bandas del espectro solar. La cantidad global que se recibe en la Tierra debe contemplar también que sólo una parte es iluminada en cada momento, con lo que la radiación solar promedio se calcula en 342 W m^{-2}. Lógicamente la cantidad que se recibe en cada lugar y momento va a depender de las condiciones de transmisividad de la atmósfera y de la altura del Sol. El primer factor es difícil de predecir, pues los componentes de la atmósfera varían mucho en el espacio y en el tiempo. El segundo es más fácilmente modelable, ya que la inclinación de los rayos solares puede calcularse a partir de la latitud, hora del día y día del año. A partir del ángulo cenital (el que forman los rayos del Sol con la vertical), puede calcularse el área efectiva que es iluminada, corrigiendo así la irradiancia solar para cada punto (fig. 2.7). Este aspecto es clave, pues explica, por ejemplo, el distinto calentamiento del planeta en función de la latitud.

Puesto que la radiancia que capta un sensor en el rango del espectro que estamos considerando depende de la que reflejan las distintas cubiertas terrestres, para detectar una cubierta por teledetección es preciso explicar cómo interactúa con la radiación solar incidente. En este sentido, conviene considerar que el flujo incidente (ϕ_i) puede

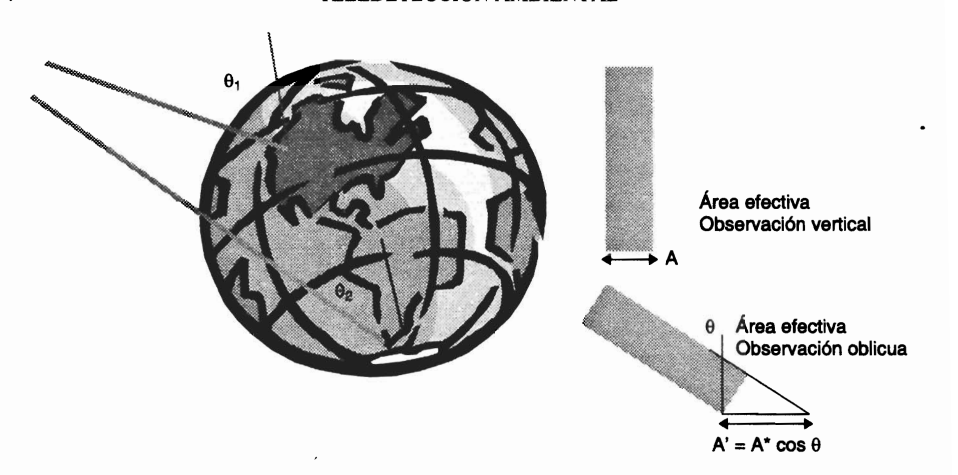


FIG. 2.7. *Efecto del ángulo cenital sobre la radiancia efectiva.*

descomponerse en tres términos: flujo reflejado (ϕ_r), flujo absorbido (ϕ_a), y flujo transmitido (ϕ_t) (fig. 2.8):

$$\phi_i = \phi_r + \phi_a + \phi_t \tag{2.9}$$

Resulta más conveniente expresar esta fórmula en unidades relativas. Para ello, basta dividir cada término de la expresión anterior por ϕ_i:

$$\frac{\phi_i}{\phi_i} = \frac{\phi_r}{\phi_i} + \frac{\phi_a}{\phi_i} + \frac{\phi_t}{\phi_i} \tag{2.10}$$

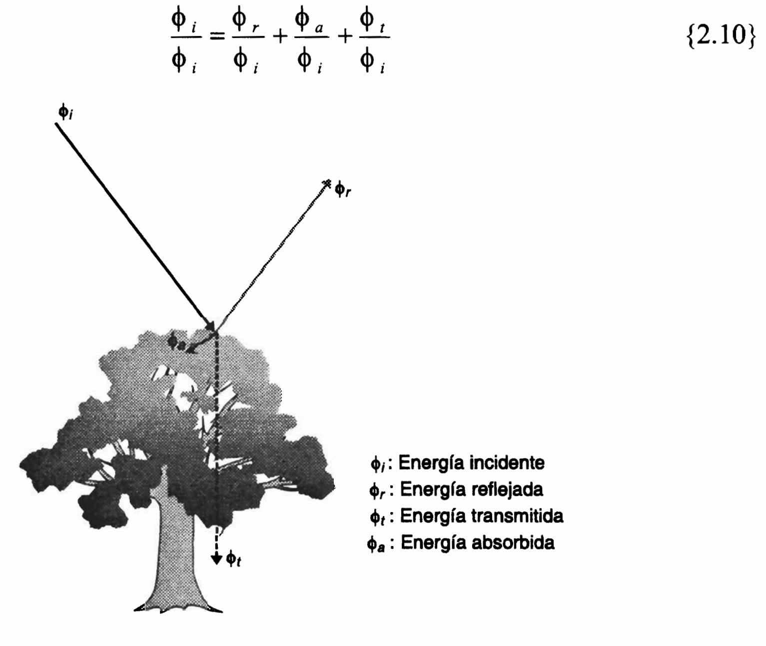


FIG. 2.8. *Descomposición del flujo solar incidente.*

o lo que es lo mismo:

$$1 = \rho + \alpha + \tau \qquad \{2.11\}$$

Lo que quiere decir, en definitiva, que la suma de la reflectividad, absortividad y transmisividad ha de ser igual a uno. La relación entre las tres magnitudes no es constante, sino que varía con la longitud de onda (λ); por tanto, en términos más rigurosos, la fórmula anterior debería expresarse como:

$$1 = \rho_\lambda + \alpha_\lambda + \tau_\lambda \qquad \{2.12\}$$

La proporción del flujo incidente que es reflejado, absorbido y transmitido depende de las características de la superficie que se observa y de la longitud de onda a la que sea observado. Para poder caracterizar una determinada cubierta nos resulta muy interesante conocer su comportamiento reflectivo en diversas longitudes de onda, ya que esto facilitará discriminarlo frente a cubiertas espectralmente similares.

En el caso del espectro visible, ese comportamiento disimilar de los objetos a distintas longitudes de onda se manifiesta en lo que llamamos color: un objeto es azul si refleja intensamente la energía en esa banda del espectro y poco en el resto (dicho de otro modo, si absorbe o transmite poca energía incidente sólo en el azul, siendo mayor la absorción en el resto), mientras será verde si su reflectividad se centra en esa banda y es baja en otras.

A partir de medidas de laboratorio, pueden obtenerse unas curvas de reflectividad espectral para las principales cubiertas terrestres, que suelen denominarse signaturas o firmas espectrales (fig. 2.9). Como puede observarse, algunas cubiertas tienden a presentar una respuesta uniforme en distintas longitudes de onda, mientras otras ofrecen un comportamiento mucho más selectivo. Por ejemplo, la nieve presenta una reflectividad alta y constante en las bandas del visible (de ahí su color blanco), pues refleja la mayor parte de la energía incidente en esas longitudes de onda. Por el contrario, el agua absorbe la mayor parte de la energía que recibe, tanto más según nos situamos en longitudes de onda mayores. Por su parte, la vegetación presenta un comportamiento muy cromático, con bajos valores de reflectividad en el espectro visible, más elevados en el infrarrojo cercano y menores en el medio. Finalmente, los materiales de construcción poseen un comportamiento similar en las distintas longitudes de onda.

Más adelante en este capítulo se analizarán con detalle estos valores típicos de reflectividad para el caso de la vegetación, agua y suelo. Antes de ello, es importante considerar que el flujo de energía recibido por el sensor no sólo depende de la reflectividad de la cubierta, sino también de otros factores externos. Los más importantes son: (i) las condiciones atmosféricas, (ii) el emplazamiento ambiental de la cubierta y (iii) la geometría de observación.

Los dos primeros aspectos se tratarán en el cap. 6.2. En cuanto a las condiciones de observación, conviene tener presente que la cantidad de energía que llega al sensor depende del ángulo con que la superficie refleje la energía incidente, así como del que formen el haz incidente con la posición del sensor. Esta geometría de observación está estrechamente ligada a la rugosidad que presenta la superficie. A este respecto, pueden distinguir-

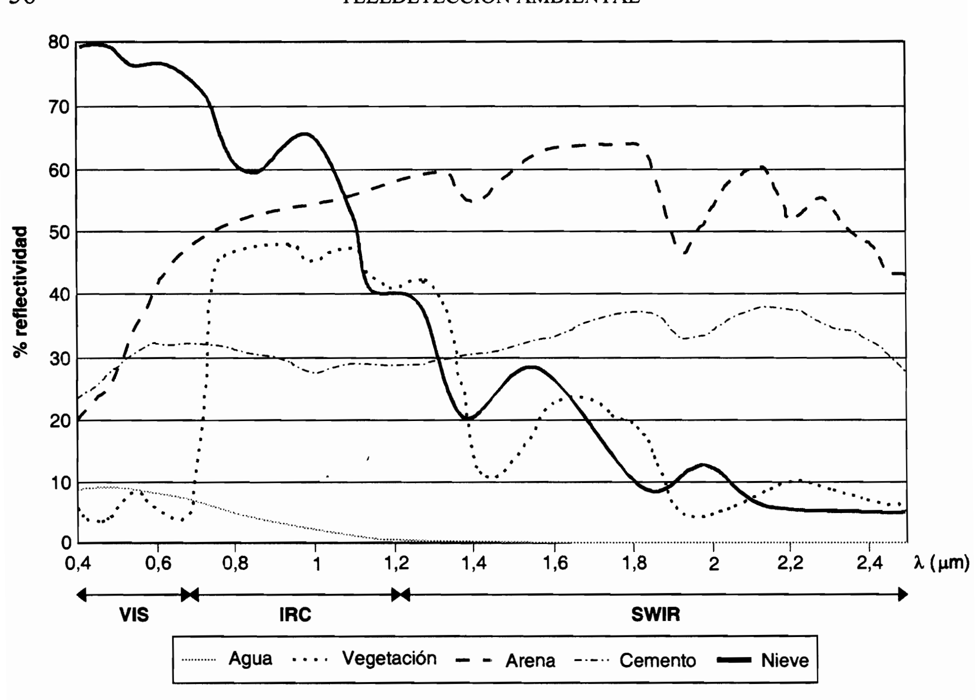


FIG. 2.9. *Signaturas espectrales típicas para distintas cubiertas (datos adquiridos con un espectro-radiómetro GER-2600).*

se dos tipos de cubiertas (fig. 2.10): aquellas que reflejan la energía con el mismo ángulo del flujo incidente (especulares), y aquellas que lo reflejan uniformemente en todas las direcciones (lambertianas). En el primer caso, el sensor sólo recibe energía reflejada del suelo si está situado en la dirección del ángulo de reflexión, siendo nula en cualquier otro caso. Si la superficie es lambertiana, la radiancia reflejada es constante en cualquier ángulo de reflexión. La mayor parte de las cubiertas tienden a comportarse de modo intermedio entre ambas situaciones, en función de sus características y de la longitud de onda en la que se trabaje. Si la longitud de onda es pequeña, las rugosidades del terreno tenderán a difundir mucho más la energía incidente que si se trata de longitudes de onda mayores, en donde esos rasgos pueden no impedir un comportamiento especular. En el espectro visible, por ejemplo, sólo el agua en calma o algunos materiales de construcción presentan un carácter casi especular, mientras el resto de las cubiertas tienden a ofrecer un comportamiento difuso. En longitudes de onda mayores (micro-ondas), también otras cubiertas pueden comportarse de modo especular, siempre que la rugosidad del terreno sea suficientemente pequeña. En general, los modelos para el cálculo de reflectividad tienden a asumir que las cubiertas presentan un comportamiento lambertiano, ya que esto simplifica mucho los cálculos al ser independientes de los ángulos de observación. En la práctica, la mayor parte de las superficies presentan una clara reflectividad direccional, esto es, la reflexión es más intensa en ciertas direcciones, por lo que se intentan considerar este factor en los modelos de cálculo más avanzados (ver cap. 6).

En cualquier caso, el ángulo de iluminación solar y el ángulo de observación juegan un papel muy destacado en la respuesta finalmente obtenida por el sensor. En pocas

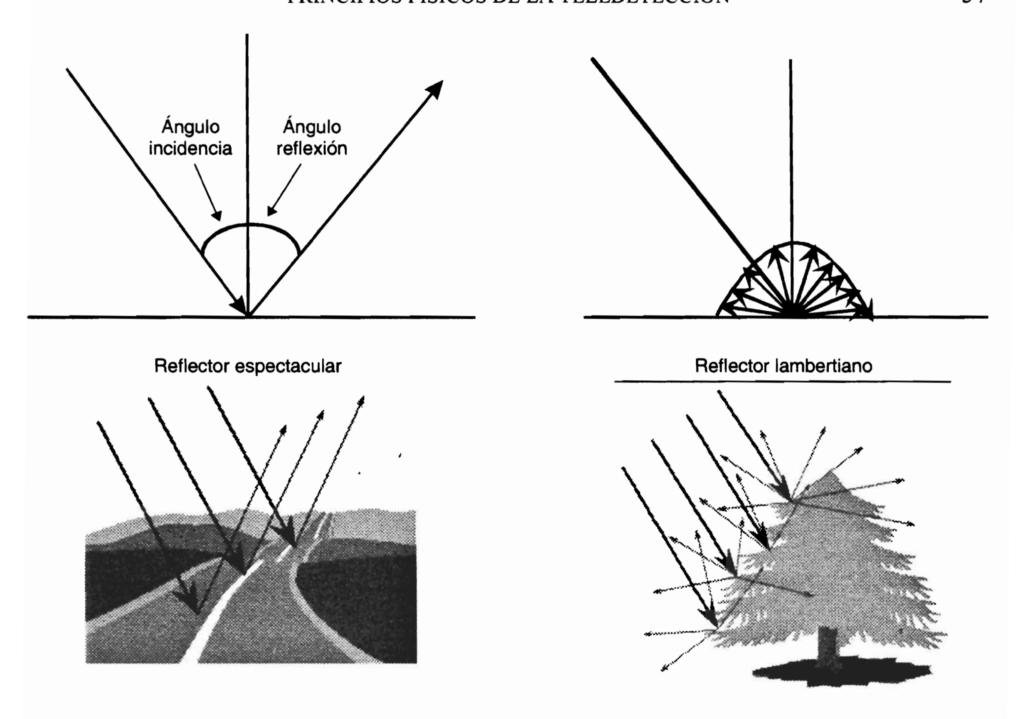


FIG. 2.10. *Tipos de comportamiento reflectivo.*

palabras, el sensor puede registrar un valor distinto de radiancia espectral para un mismo tipo de cubierta —con la misma o similar reflectividad—, si varían las condiciones de observación o de iluminación. Además, es preciso tener en cuenta que una superficie vegetal puede presentar distintos grados de cobertura a lo largo del año, por lo que podríamos hablar incluso de una signatura espectro-temporal, que permitiría mejorar la discriminación de una determinada cubierta siguiendo su dinamismo estacional.

Considerar todos estos factores subraya la complejidad que la observación remota lleva consigo, ya que el comportamiento de una cubierta en el espectro visible está influido no sólo por sus propias características, sino también por una serie de factores externos que modifican lo que podríamos llamar su comportamiento espectral teórico. Algunos de estos factores son (fig. 2.11):

— Ángulos de iluminación y observación (i), que varían con la latitud, fecha del año y hora de observación, además de la posición del sensor.

— Modificaciones que el relieve introduce en el ángulo de iluminación: orientación de las laderas (ii) o pendiente (iii).

— Influencia de la atmósfera, especialmente en lo que se refiere a la absorción por nubes (iv) y a la dispersión selectiva en distintas longitudes de onda.

— Variaciones medioambientales en la cubierta: asociación con otras superficies, homogeneidad que presenta, estado fenológico (v), etc.

— Sustrato edafológico o litológico (vi), especialmente influyente cuando la cubierta observada presenta una densidad media.

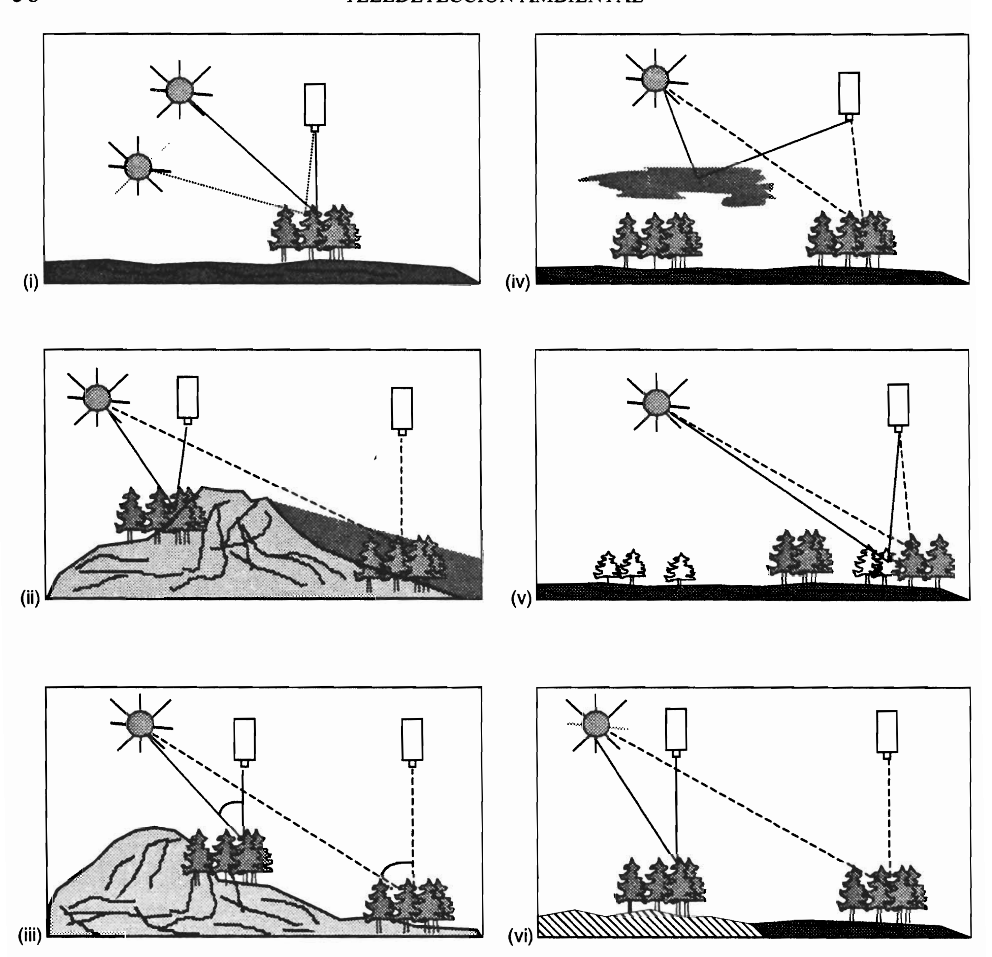


FIG. 2.11. *Factores que modifican la firma espectral de una cubierta: (i) variaciones en las condiciones de observación o iluminación; (ii) orientación de la vertiente; (iii) pendiente; (iv) atmósfera; (v) condición fenológica; (vi) sustrato edáfico.*

A ello habría que añadir que la radiación incidente en una determinada superficie no sólo es la directa solar, sino también la proveniente de superficies vecinas o de la propia atmósfera, ya que las reflexiones se producen en múltiples direcciones. Este fenómeno, conocido como irradiancia difusa, tiene gran importancia en áreas de baja iluminación, como veremos más adelante.

Estos factores expresan la complejidad que puede entrañar la caracterización de un tipo de cubierta a partir de sensores remotos. También nos sirven para matizar un tanto la validez de las curvas espectrales indicadas previamente, que no deben considerarse más que como reflectividades de referencia. Este modo peculiar con el que una determinada cubierta refleja o emite energía a distintas longitudes de onda se ha denominada comúnmente firma espectral (Meliá *et al.*, 1986; Slater, 1980), y resulta la base para discriminar dicha cubierta de otras a partir de la observación remota. Ahora bien, como venimos comentando, además del comportamiento espectral propio de

cada cubierta, es preciso considerar los factores arriba indicados, que modifican esa signatura característica. En suma, las distintas cubiertas de la superficie terrestre no tienen un comportamiento espectral único y permanente, que coincida con sus curvas de reflectividad espectral y permita reconocerlas sin confusión frente a otras superficies. Por el contrario, en torno a la firma espectral las distintas cubiertas presentan una cierta variabilidad, debida a los factores ya comentados, y que dificulta —en última instancia— su discriminación de otras superficies.

Pese a estos comentarios, no cabe duda que las curvas de reflectividad antes analizadas son muy útiles para interpretar más fielmente la imagen, por cuanto relacionan los valores adquiridos por el sensor con las medidas de laboratorio. A la vez, estas gráficas nos permiten seleccionar las bandas más convenientes para la detección de las cubiertas terrestres bajo estudio.

5.2. Medios para obtener firmas espectrales

Las firmas espectrales son fundamentales para reconocer cubiertas de interés, o parámetros dentro de esas cubiertas (clorofila en la vegetación o turbidez en el agua, por ejemplo), por lo que se recomienda que sean punto de partida para la mayor parte de los trabajos de teledetección. La firma espectral de una cubierta puede obtenerse a partir de varias fuentes: (i) medirla con un radiómetro, (ii) extraerla de una biblioteca espectral puesta a punto por alguna institución, (iii) simularla mediante modelos físicos, o (iv) extraerla de una imagen con la debida resolución espectral.

A los radiómetros dedicaremos un apartado en el capítulo 3, en el que se revisan los distintos sensores disponibles para teledetección. La simulación de la señal la cubriremos con más detalle en el capítulo 7, centrado en el uso de modelos físicos para ayudar en la interpretación de la imagen. La extracción de una firma espectral de una imagen con un buen número de bandas se cubrirá con más detalle en el apartado dedicado a teledetección hiperespectral, también en el capítulo 7. Por ahora nos centraremos en las bibliotecas espectrales, que son el medio mas sencillo de disponer de firmas espectrales para la enseñanza o investigación introductoria.

5.3. Bibliotecas espectrales

El creciente desarrollo que en los últimos años están teniendo los sensores de muy alta resolución espectral ha estimulado la creación de bibliotecas espectrales. Se trata de colecciones de firmas espectrales, tomadas con radiómetros de laboratorio en condiciones controladas, que sirven de referencia para conocer el comportamiento tipo de una determinada cubierta.

Estas bibliotecas se están utilizando para calibrar los valores de reflectividad estimados a partir de la imagen, facilitar el entrenamiento automático en la interpretación de cubiertas y servir como entrada para la extracción de modelos de mezclas espectrales (ver 7.1.6.1).

Aunque todavía son escasas las bibliotecas espectrales disponibles, conviene citar la desarrollada por el Servicio Geológico Estadounidense (USGS: (Clark *et al.*,

1993), accesible a través de internet (http://speclab.cr.usgs.gov/spectral-lib.html última entrada 20-2-2008), que cuenta con una amplia variedad de espectros, aunque son muy escasos los correspondientes a cubiertas vegetales. Esta biblioteca está bien documentada y cubre el rango de 0,2 a 3 μm.

Algo más reciente es la biblioteca espectral compilada por el *Jet Propulsión Laboratory* (JPL), denominada ASTER (http://speclib.jpl.nasa.gov, última entrada 20-2-2008) con casi 2.000 curvas espectrales situadas entre 0,4 y 2,5 μm, aunque para muchas de ellas se ofrece información hasta el infrarrojo térmico (15 μm). Este proyecto parte de la biblioteca compilada por el USGS, la Universidad *John Hopkins* y el propio JPL. Incluye espectros de minerales, rocas, suelos, meteoritos, vegetación (solamente 4 especies), agua, nieve y cubiertas humanas (asfalto, cemento, aluminio, cobre, papel, diversos tipos de pinturas, etc.). Para cada espectro se incluye un archivo de documentación, que facilita datos sustanciales sobre la fuente y condiciones de adquisición y el tipo de material observado (incluyendo tamaño de las partículas y composición química), si bien los espectros, al provenir de fuentes diversas, se tomaron con diferentes criterios y no son completamente comparables.

Otras bibliotecas menos conocidas que la desarrollada en la Universidad de Purdue, uno de los centros pioneros en aplicaciones agrícolas de la teledetección, centrada en cultivos, son la que desarrolló Dar Roberts (Universidad de California Santa Bárbara) para especies de chaparral californiano (Roberts *et al.*, 1998), la realizada en el marco del proyecto europeo STORMS: *Silvicultural Techniques Offering Risk Minimising Strategies*, desarrollada en Portugal y centrada en mediciones de todas las superficies y cubiertas que puedan tener alguna influencia en el riesgo de incendios forestales, y la realizada por el departamento de Geografía de la Universidad de Alcalá, sobre especies vegetales mediterráneas (http://www.geogra.uah.es/~espectra/index.html última entrada 20-2-2008).

5.4. Comportamiento espectral de la vegetación en el espectro óptico

La caracterización espectral de las masas vegetales constituye una de las tareas más interesantes en teledetección. Pese a su gran importancia, aún ofrece notables dificultades como consecuencia de los múltiples factores que influyen en la radiancia que finalmente detecta el sensor. Podemos dividir estos factores en tres grandes grupos (Belward, 1991; Colwell, 1974; Gausman, 1977; Guyol *et al.*, 1989; Sellers, 1989):

— Los relacionados con la reflectividad de la hoja, que suele ser el elemento más visible desde una plataforma espacial. Aquí los factores más destacados son la presencia de pigmentos, la estructura celular y el contenido de humedad.

— Las características geométricas de la planta, principalmente su área foliar, la forma de las hojas, su distribución en la planta, la geometría del dosel, la importancia del componente leñoso, etc.

— Finalmente, habría que considerar aquellos aspectos derivados de la situación geográfica de la planta: pendiente, orientación, asociación con otras especies, reflectividad del sustrato, geometría de plantación, condiciones atmosféricas, etc.

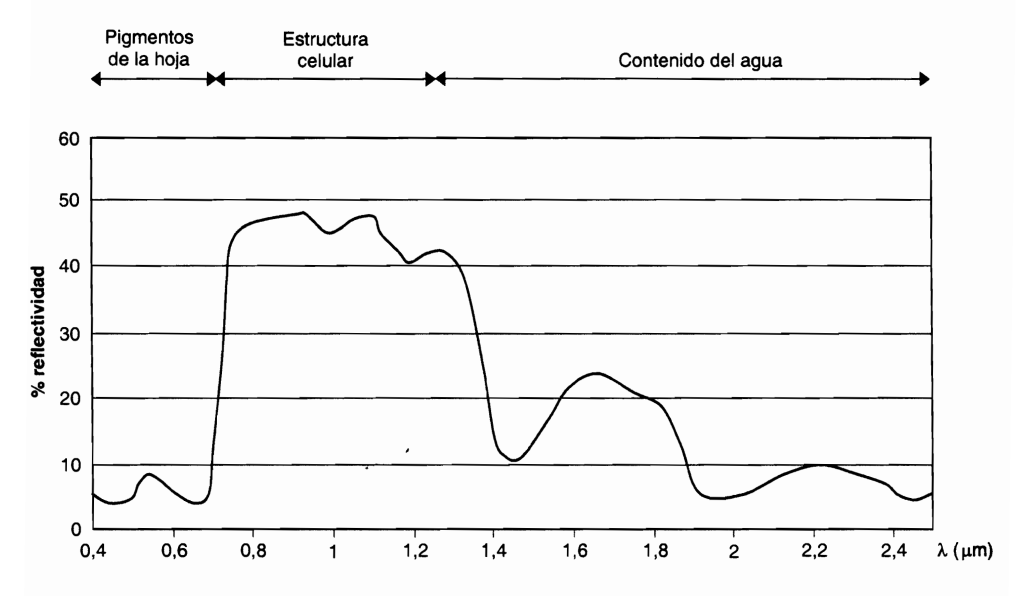


FIG. 2.12. *Factores que explican la reflectividad de la hoja.*

En lo que se refiere a la reflectividad de la hoja, podemos basarnos en estudios realizados a partir de espectro-radiómetros en laboratorio (Colwell, 1974; Curran, 1980; Gates *et al.*, 1965; Knipling, 1970; Lusch, 1989). Las curvas espectrales resultantes varían en relación con el tipo de hoja, si bien podemos establecer unos patrones generales, marcados por la baja reflectividad en el visible, alta en el IRC y baja, con presencia de algunos máximos relativos, en el SWIR (figs. 2.9 y 2.12).

En concreto, la baja reflectividad en la porción visible del espectro se debe al efecto absorbente de los pigmentos de la hoja, principalmente las clorofilas, xantofila y caroteno (65, 29 y 6 %, respectivamente, aunque la proporción puede variar mucho: [Gates *et al.*, 1965]). Todos ellos absorben en la banda del espectro situada en torno a los 0,445 μm, mientras la clorofila presenta una segunda banda de absorción en torno a los 0,645 μm. Entre ambas porciones del espectro, aparece una banda intermedia, alrededor de los 0,55 μm, en donde el efecto absorbente es menor. Por esta causa aparece un pico relativo de reflectividad que coincide con la banda verde del espectro visible, y causa el color con el que nuestros ojos perciben la vegetación vigorosa.

Cuando se aproxima la caída otoñal de las hojas, la clorofila ejerce una menor influencia, lo que explica su mayor reflectividad en la banda roja y, en definitiva, su color amarillento (verde + rojo). En algunas especies resulta destacada la acción de otro pigmento, la antocianina, buen reflector de la porción roja del espectro, que causa ese color en épocas de senescencia (caso de los arces canadienses o la lenga chilena).

La elevada reflectividad en el infrarrojo cercano se debe, por un lado, a la baja absortividad de las clorofilas, y, por otro, a la estructura celular interna de la hoja. Como es sabido, la hoja se compone, en esencia, de cuatro capas: la epidermis superior e inferior, el parénquima en empalizada y el mesófilo esponjoso. Las dos primeras juegan un importante papel en la regulación térmica de la planta y en su absorción de CO_2. El parénquima alberga los cloroplastos, mientras en el mesófilo tienen lugar los

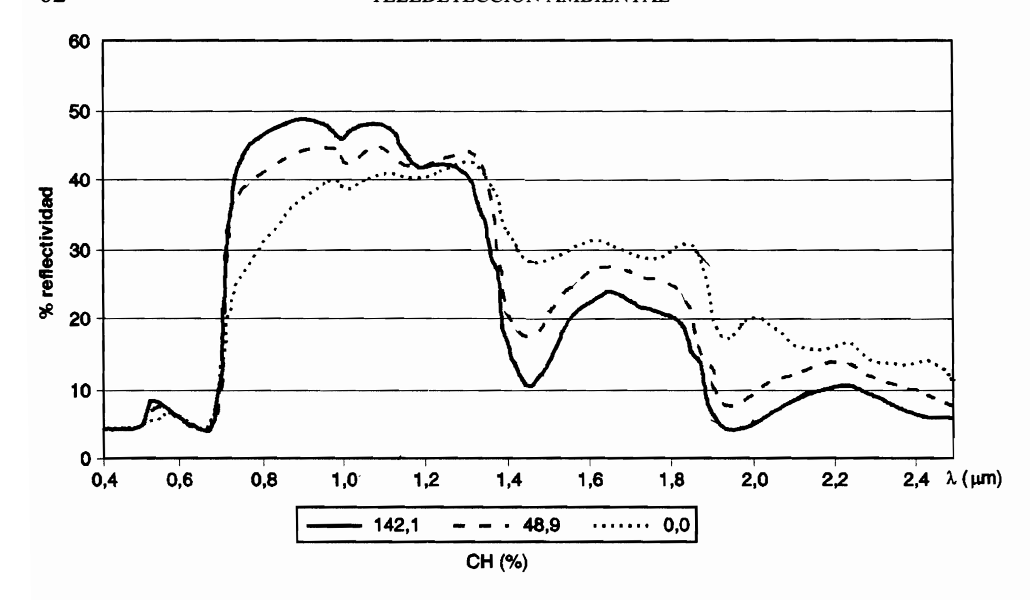


FIG. 2.13. *Curvas de reflectividad para hojas de jara* (Cistus ladanifer) *con distintos contenidos de humedad (datos adquiridos con un espectro-radiómetro GER-2600).*

intercambios gaseosos necesarios para la respiración de la planta. Debido a ello, cuenta con unas cavidades de aire internas, que dispersan la mayor parte de la radiación incidente en el IRC (Gates *et al.*, 1965; Horler *et al.*, 1983). Por ello, la hoja sana ofrece una alta reflectividad en esta banda, en claro contraste con la baja reflectividad que presenta en el espectro visible, especialmente en la banda roja. Puesto que la estructura de la hoja es muy variada según las especies, esta banda también resulta idónea para discriminar entre plantas, incluso entre aquellas que no podrían separarse en el espectro visible.

A partir de 1,4 μm el efecto absorbente del agua es muy claro, por lo que la reflectividad de la vegetación sana se reduce drásticamente en el SWIR. Las medidas de laboratorio muestran una notable diferencia en esta región del espectro entre las hojas secas y las infiltradas con agua (Bowman, 1989; Hunt *et al.*, 1987). En experimentos con hojas de higuera, la reflectividad de la hoja seca alcanzó hasta cuatro veces el valor de la hoja húmeda, para la banda situada en torno a 1,9 μm (Short, 1982). En otros estudios sobre hojas de coníferas, se observó un sensible aumento de la reflectividad en el infrarrojo medio según se iban desecando las hojas, disminuyendo ligeramente en el infrarrojo cercano y con escasa variación en el visible (Westman y Price, 1988). En especies mediterráneas de matorral y arbolado, también se han comprobado estas buenas relaciones, de signo negativo, entre contenido de humedad y reflectividad en el SWIR (De Santis *et al.*, 2006; Riaño *et al.*, 2000; Vaughan, 2001) (fig. 2.13). Entre estas bandas, donde la absorción del agua es más clara, se sitúan dos picos relativos de reflectividad, en torno a 1,6 μm y 2,2 μm. Queda patente, pues, que la observación en el SWIR es de gran interés para conocer el estado hídrico de la hoja.

Obviamente el sensor no mide hojas aisladas, sino agrupaciones de hojas formando plantas o masas de vegetación, por lo que además de la reflectividad de la hoja

es preciso tener en cuenta otros elementos adicionales que complican el esquema previo. Para no alargar excesivamente esta exposición, conviene aquí citar tres grupos de factores: la geometría de la planta, los ángulos de observación e iluminación, y las características del sustrato. De ellos, tal vez el más destacado es la proporción hoja-suelo que observa el sensor, siendo la reflectividad de la planta más similar a la de la hoja cuando los porcentajes de cobertura son elevados y los ángulos de iluminación y observación verticales. Aunque el grado de cobertura verde del suelo (PV) es un parámetro clave en teledetección, habitualmente se maneja en su lugar el índice de área foliar (LAI), más empleado en el campo de la fisiología vegetal, ya que de alguna manera hace referencia a la productividad neta de la planta. El LAI se relaciona directamente con la PV hasta un cierto nivel de saturación (100 % de PV). Ese valor crítico se alcanza cuando el LAI se sitúa entre 3 y 6, según los ecosistemas. A partir de ahí, puede seguir aumentando el LAI, aunque el PV ya se mantenga estable, como consecuencia del apilamiento vertical de las hojas (Sellers, 1987).

En los últimos años se han desarrollado diversos modelos de simulación de reflectividad (Goel, 1988), que permiten analizar el impacto teórico de alterar alguno de los parámetros que afectan a la reflectividad de la hoja o del dosel vegetal. Para estos últimos, suelen introducirse como variables de entrada la reflectividad de la hoja, el LAI, la distribución geométrica de las hojas, y los ángulos de observación e iluminación (Barnsley y Hobson, 1997; Danson, 1998; Liang, 2004). Más adelante (7.1.1) comentaremos con más detenimiento las posibilidades de estos modelos.

Simplificando un poco las cosas, podemos resumir que la observación remota de las cubiertas vegetales puede apoyarse en el gran contraste cromático que presenta la vegetación vigorosa entre las distintas bandas del espectro, y singularmente entre el visible (alta absorción, baja reflectividad) y el IRC (alta reflectividad). De ahí que podemos enunciar, como principio genérico, que cuanto mayor sea el contraste entre esas dos bandas, mayor será la cobertura vegetal y/o el vigor de la vegetación, y más clara su discriminación frente a otros tipos de cubierta. Este comportamiento espectral teórico de las cubiertas vegetales ha sido la base para obtener una serie de índices de vegetación, que se basan precisamente en el contraste entre las bandas R e IRC del espectro. Se construyen a partir de la combinación entre estas dos bandas, cuando disponemos de una imagen multiespectral. Muy variados en su desarrollo, todos ellos tienden a presentar de forma más nítida las características de la vegetación, facilitando su aislamiento de otras cubiertas y la detección de su estado vital (Bannari *et al.*, 1995; Curran, 1981; Myneni *et al.*, 1995; Sellers, 1989). Más adelante se estudiará el interés temático de estas transformaciones (7.1.2).

Queda implícito que cualquier fuente de estrés en la vegetación se mostrará en un comportamiento espectral más o menos alejado del anteriormente expuesto. La hoja senescente o enferma tiende a perder actividad clorofílica y, en consecuencia, a ofrecer una menor absortividad en las bandas azul y roja del espectro visible. El aumento consecuente de la reflectividad en estas bandas elimina el máximo relativo antes situado en el verde, por lo que la hoja tiende a mostrar un color amarillento. Por el contrario, en el infrarrojo cercano se produce una reducción de la reflectividad, como consecuencia de un deterioro en la estructura celular de la hoja. La curva espectral, por tanto, se hace más plana, menos cromática (Jackson *et al.*, 1986; Knipling, 1970; Murtha, 1978). Estas observaciones son válidas para detectar daños producidos por plagas o incen-

dios forestales (Chuvieco *et al.*, 2006; Vogelman, 1990). Además, se ha comprobado que ciertos factores de estrés en la hoja están asociados a un desplazamiento en el límite del rojo *(red edge)* —esto es, en el cambio de pendiente de la curva espectral entre el rojo y el infrarrojo cercano—, hacia longitudes más cortas. Este fenómeno se ha observado, por ejemplo, cuando las plantas están afectadas por contaminación de metales pesados (Rock *et al.*, 1988; Westman *et al.*, 1988).

Por otro lado, En varios estudios, se ha comprobado una clara relación entre el cociente IRC/SWIR y el contenido de humedad en las hojas, lo que permite determinar aquellas zonas afectadas por estrés hídrico (Ceccato *et al.*, 2001; Hunt y Rock, 1989; Zarco-Tejada *et al.*, 2003).

5.5. El suelo en el espectro óptico

Como consecuencia del efecto de pantalla provocado por la cubierta vegetal, no resulta sencillo obtener información del sustrato geológico a partir de sensores espaciales. Sin embargo, pueden obtenerse algunos datos indirectos sobre las características del suelo/litología gracias a las anomalías que puedan detectarse en esa cubierta vegetal. Ejemplos de este tipo de modificaciones son: distribución peculiar de especies, crecimiento o densidad irregular, alteraciones de la pigmentación o del ciclo fenológico, etc. Si bien no todos estos fenómenos pueden ser imputados al sustrato geológico, algunos estudios han demostrado la posibilidad de inferir valiosa información de éste a partir de la vegetación (Lulla, 1985; Milton *et al.*, 1983). Esta técnica se ha bautizado con el nombre de geobotánica, demostrando gran interés para estudios regionales (Bruce y Hormsby, 1987).

En lo que atañe a los suelos desnudos, su comportamiento espectral es mucho más uniforme que el de la vegetación, mostrando una curva espectral más plana. Los principales factores que intervienen en este caso son la composición química del suelo, su textura, estructura y contenido de humedad (Labrandero, 1978).

La composición química es la causa del color dominante con el que percibimos el suelo (fig. 2.14). Los de origen calcáreo tienden al color blanco, indicando una alta reflectividad en todas las bandas visibles. Por su parte, los suelos arcillosos ofrecen una mayor reflectividad en el rojo, como consecuencia de su alto contenido en óxido de hierro. El contenido de humus resulta muy influyente en su color, tendiendo a una baja reflectividad, especialmente en torno a 0,7-0,75 µm (Curran *et al.*, 1990).

Respecto a las características físicas del suelo, puede afirmarse, en términos generales, que la reflectividad espectral resulta tanto mayor cuanto se trate de suelos más finos y apelmazados (Lusch, 1989).

El contenido de humedad es uno de los elementos más destacados en la reflectividad del suelo para estas longitudes de onda, como consecuencia de la alta absortividad del agua en estas bandas. Influye inversamente en la reflectividad del visible e infrarrojo, en torno a 1,45 µm y 1,92 µm, con mayor intensidad en las bandas de absorción del agua.

Como es bien sabido, textura, estructura y contenido de humedad están altamente relacionados. Por ejemplo, un suelo arcilloso tiende a retener mejor la humedad, lo que supone una baja reflectividad, pese a ser de fina textura. En contraste, un suelo

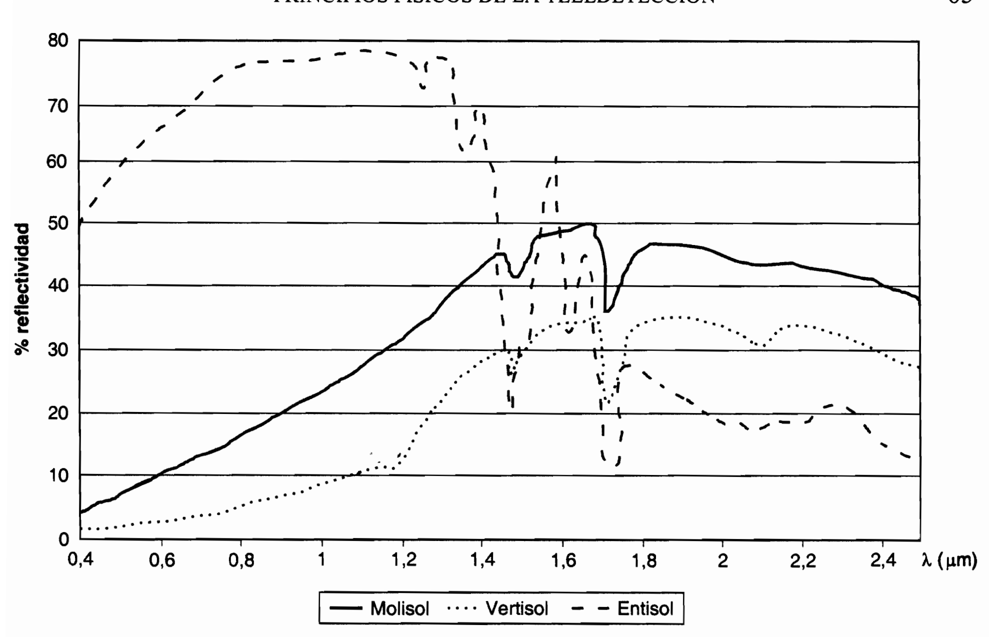


FIG. 2.14. *Curvas de reflectividad para distintos tipos de suelos: Molisol (limoso pardo-grisáceo); Vertisol (arcilloso-marrón); Entisol (yeso blanco). Datos tomados de la biblioteca espectral Aster.*

arenoso tiende a tener una débil estructura y bajo contenido de humedad, por lo que presentará, en función de esos factores, una reflectividad más elevada (Curran, 1985). A ello convendría añadir el efecto de la materia orgánica en el suelo, que tiende a oscurecerle y, en consecuencia, a reducir su reflectividad.

5.6. EL AGUA EN EL ESPECTRO ÓPTICO

Las superficies acuáticas absorben o transmiten la mayor parte de la radiación óptica que reciben, siendo mayor su absortividad cuanto mayor sea la longitud de onda. La curva espectral, por tanto, es similar a la del suelo, aunque de sentido contrario. La mayor reflectividad del agua clara se produce en el azul, reduciéndose paulatinamente hacia el infrarrojo cercano y medio, donde ya es prácticamente nula. Por esta razón, la frontera tierra-agua es muy nítida en esta banda.

La variabilidad del agua es más fácilmente detectable en las longitudes de onda más cortas (azul y verde). Se relaciona con su profundidad, contenido de materiales en suspensión (clorofila, sedimentos y nutrientes), y rugosidad de la superficie. La turbidez del agua, relacionada con su contenido de sedimentos, implica aumento de la reflectividad en todas las bandas del visible, para distintos diámetros de partícula (Bhargava y Mariam, 1990). El efecto se hace especialmente evidente en la desembocadura de los grandes ríos (fig. 2.15).

La profundidad del agua influye directamente en el aporte de reflectividad derivado de los materiales de los fondos. En aguas poco profundas la reflectividad aumen-

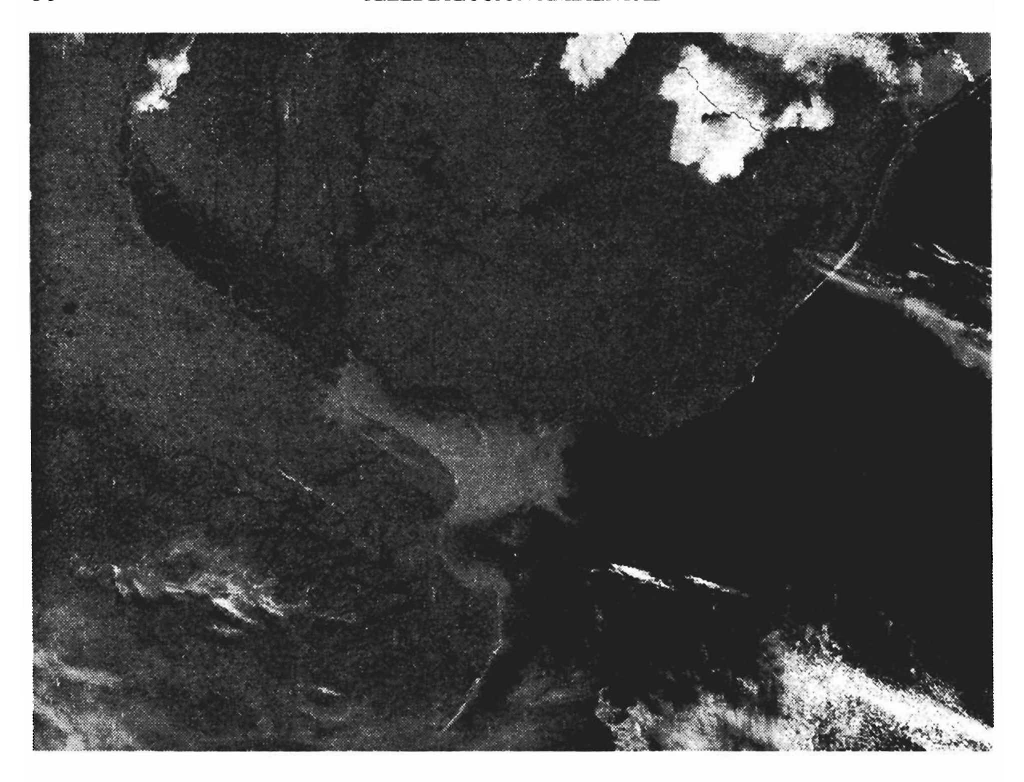


FIG. 2.15. *Sedimentos en suspensión en la desembocadura del Río de la Plata. Imagen Terra MODIS del verano de 2002.*

ta, ya que hay mayor aporte de la radiancia reflejada por los fondos. En consecuencia, la absortividad será tanto mayor cuanto más profunda sea la capa de agua. A partir de esta relación pueden abordarse algunos estudios de batimetría en zonas costeras. Para imágenes Landsat-TM se estima que la profundidad de agua máxima que puede determinarse alcanza 6,4 m en la banda azul, 3 en la verde y 2,1 en la roja (Ji *et al.*, 1992).

En cuanto a su composición, diversos estudios han demostrado la posibilidad de emplear sensores espaciales para cartografiar contenido de clorofila en el agua (Domínguez *et al.*, 2003; López y Caselles, 1989). Si el agua ofrece importantes concentraciones de clorofila, la reflectividad en el azul tiende a descender, aumentando en el verde. Esto permite establecer una clara correlación, de signo negativo, entre la reflectividad del agua en la banda azul y el contenido de clorofila, lo que facilita localizar concentraciones de algas (Robinson, 1985), analizar ritmos de productividad neta de la superficie marina o estudiar procesos de eutrofización en embalses (Ruíz-Verdú *et al.*, 2001; Verdin, 1985).

El resto de los materiales en suspensión contribuyen también a aumentar la reflectividad, además de presentar una mayor turbidez. Por último, la rugosidad de la superficie favorece la reflexión difusa, y en consecuencia una mayor reflectividad. En caso de aguas muy tranquilas, la superficie se comporta de modo especular, con valores de reflectividad muy variados en función de la localización del sensor. En el caso de las medidas tomadas con sensores espaciales, los valores resultan extremadamente bajos.

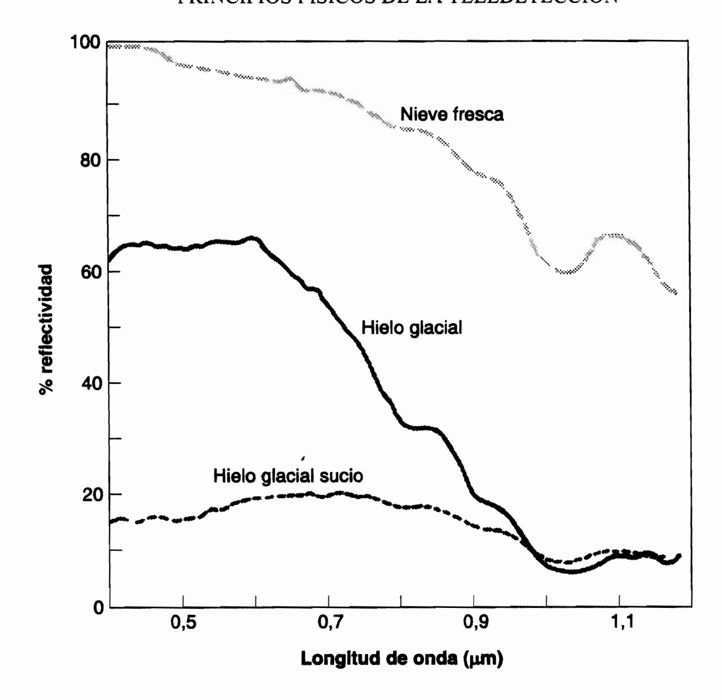


FIG. 2.16. *Curvas de reflectividad para distintos tipos de nieve (adaptado de Hall y Martinec, 1985).*

La nieve, por su parte, ofrece un comportamiento muy distante del agua. Presenta una reflectividad elevada en las bandas visibles, reduciéndose en el infrarrojo cercano y más claramente en el medio. Los factores más destacados en la reflectividad de la nieve son el tamaño del grano, la profundidad y densidad de la capa y la cantidad de impurezas que contenga (Kelly y Hall, 2008). La reflectividad es mayor para la nieve fresca que para la helada, mostrando los valores más bajos la nieve sucia (fig. 2.16). La reducción puede llegar hasta el 80 % para las bandas visibles (Hall, 1988; Hall y Martinec, 1985).

A veces no resulta sencillo distinguir la nieve de las nubes en el espectro visible. La distinción resulta más evidente en el infrarrojo medio, ya que las gotas o cristales de hielo de las nubes son más pequeños que los granos de nieve, por lo que absorben menos radiación en esta banda del espectro. Además, habitualmente, la nieve tiene mayor reflectividad que las nubes en el visible y una textura más homogénea (Dozier, 1989).

6. El dominio del infrarrojo térmico

6.1. CARACTERÍSTICAS DE LA RADIACIÓN ENERGÉTICA EN EL INFRARROJO TÉRMICO

De acuerdo con las leyes de Planck {2.4} y Wien {2.6}, podemos fijar entre 8 y 14 µm la banda espectral en donde se manifiesta con mayor claridad la emitancia es-

pectral de la superficie terrestre, de acuerdo a su temperatura (unos 300 K). A esta parte del espectro se le denomina infrarrojo térmico, puesto que nos permite detectar el calor que procede de las distintas cubiertas. En definitiva, para esta banda la radiancia espectral que recibe el sensor no es el resultado de la reflexión de la energía solar sobre la superficie terrestre, sino de la radiación emitida por ésta.

Como vimos, la emitancia espectral de un objeto está directamente relacionada con su temperatura absoluta. A la vez, ésta se relaciona con su capacidad para absorber la radiación solar incidente. De la fórmula {2.11} se deduce que ésta puede ser reflejada, absorbida o transmitida. Considerando que la transmisividad es prácticamente nula en el infrarrojo térmico, la expresión puede simplificarse indicando que, a estas longitudes de onda, la energía incidente o bien se refleja o bien se absorbe. Junto a ello, es preciso tener en cuenta que cuando una superficie está en equilibrio térmico con los alrededores, la ley de Kirchoff indica que la absortividad espectral es igual a la emisividad. En otras palabras, a mayor absorción, mayor emisión, por lo que podemos expresar la fórmula {2.11} indicando:

$$1 = \rho_{\lambda(T)} + \varepsilon_{\lambda(T)} \qquad \{2.13\}$$

lo que, en resumen, significa que las superficies con alta reflectividad (caso de la nieve) son poco emisivas, mientras las poco reflectivas son altamente emisivas (como ocurre con el agua).

Como ya vimos anteriormente, la emisividad de un tipo de cubierta es una medida relativa, que pone en relación su emitancia con la de un cuerpo negro. Una alta emisividad (cercana a 1) indica que un objeto absorbe y radia una gran proporción de la energía incidente, mientras una emisividad considerablemente inferior a 1, refiere a un objeto que absorbe y radia una pequeña proporción de la energía incidente. En el caso de las cubiertas de interés medioambiental, la mayor emisividad, se presenta en la vegetación densa (0,99) y el agua (0,98), mientras los valores más bajos corresponden a los suelos arenosos (0,90), nieve (0,80) y metales (0,16). Varios autores han llevado a cabo mediciones sistemáticas de la emisividad en terreno, tanto en el IRT como en el IRM (3-5μm) (Salisbury y D'aria, 1994; Salisbury y D'aria, 1992).

El contenido de humedad modifica notablemente estos valores estándar. Así en suelos arenosos se han medido incrementos de emisividad de 0,90 a 0,94 al aumentar un 8 % el contenido de humedad (Mulders, 1987). Los valores de emisividad se calculan para una temperatura media, en este caso en torno a 20° C (Curran, 1985).

A partir de la medida de la emisividad puede estimarse la emitancia global de un objeto, conociendo su temperatura. En este sentido puede corregirse la ley de Stefan-Boltzmann, introduciendo el parámetro de emisividad:

$$M_n = \varepsilon\, \sigma\, T^4 \qquad \{2.14\}$$

Esto implica que dos objetos situados a la misma temperatura pueden presentar emitancias radiantes distintas. De esta forma, parece evidente la necesidad de corregir los valores de radiancia adquiridos por el sensor considerando la emisividad, que puede estimarse siempre y cuando se conozca la cubierta detectada y ésta sea suficientemente homogénea. En caso de un área con cubiertas muy distintas, cada una de ellas

con su propia emisividad, el problema sería mucho más complejo. Habría de hacerse una corrección en función de las coberturas presentes en esa zona, conociendo la emisividad propia de cada una de ellas. En ocasiones se ha utilizado un mapa de ocupación del suelo previo para facilitar la corrección de emisividades (Caselles *et al.*, 1988), aunque también puede basarse en una correlación de radiancias-temperaturas con medidas tomadas en el terreno o en estaciones meteorológicas (Sobrino, 2000, cap. 11). Algunos trabajos han mostrado que, en cubiertas vegetales suficientemente densas, basta incorporar la emisividad de ésta y no la del suelo que la soporta, lo cual simplifica notablemente los cálculos. Más adelante, veremos con detalle los procedimientos para hacer el cálculo de la temperatura a partir de imágenes adquiridas en esta región del espectro (6.2.4).

Además de la emisividad, el comportamiento térmico de un objeto está relacionado con otros parámetros. Los más importantes son su capacidad térmica, conductividad, difusividad, inercia térmica e índice de calentamiento.

La capacidad térmica (C) indica la capacidad de la cubierta para almacenar calor. La capacidad térmica por unidad de masa se denomina calor específico (c). Las masas de agua poseen la mayor capacidad térmica, por lo que pueden almacenar más calor que la vegetación o los suelos.

La conductividad térmica (k), mide el ritmo al que se transmite el calor en esa cubierta. Las áreas urbanas son buenas conductoras de calor, mientras la vegetación o suelos resisten más esta transferencia. Por ello, la temperatura diurna en zonas de cubierta vegetal es fundamentalmente una función de la temperatura de la capa superior, y no de capas inferiores.

La difusividad térmica (a) es una medida del cambio de temperatura que se produce en el interior de la cubierta. En general, las superficies secas difunden los cambios de temperatura hacia abajo a una velocidad menor que las superficies húmedas.

Por último, la inercia térmica (P) hace referencia a la resistencia de un material a cambiar de temperatura. Este parámetro está directamente relacionado con la conductividad (k), el calor específico (c) y la densidad del material (D), de acuerdo a la siguiente fórmula:

$$P = \sqrt{Dck} \tag{2.15}$$

Los suelos secos y arenosos, con baja inercia térmica, ofrecen severos contrastes entre las temperaturas diurnas y nocturnas. En contraste, los suelos húmedos y arcillosos son mucho más resistentes al cambio y presentarán temperaturas diurnas inferiores y nocturnas superiores a los suelos secos (fig. 2.17). La inercia térmica es más fácilmente detectable en los momentos de máxima y mínima insolación, aproximadamente a las 12.00 y 24.00 h, respectivamente.

En cuanto al índice de calentamiento, es función de la intensidad de la radiación y de la absortividad del objeto. La intensidad es menor en aquellas zonas arboladas, con nubes o con edificios que impidan la radiación directa. También está afectado directamente por la pendiente o exposición de las laderas.

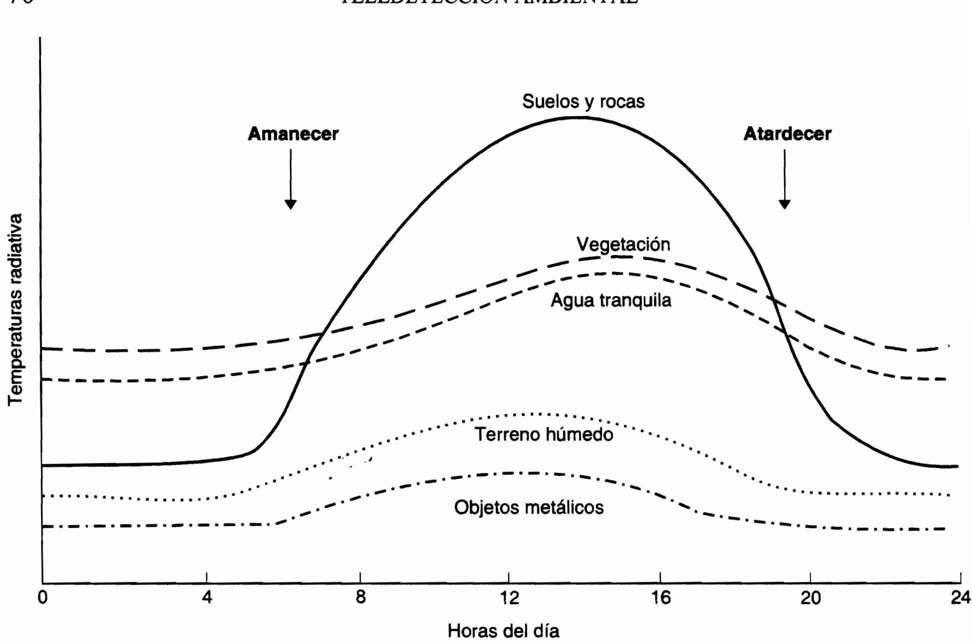


FIG. 2.17. *Inercia térmica estimada para diversas cubiertas (adaptado de Short, 1982).*

6.2. COMPORTAMIENTO ESPECTRAL DE LA VEGETACIÓN EN EL INFRARROJO TÉRMICO

Las propiedades térmicas de la vegetación son bastante complejas, puesto que absorbe una gran cantidad de la energía solar que recibe para la fotosíntesis. Esta energía es re-emitida durante la noche para mantener el balance energético.

En consecuencia, la vegetación posee una alta inercia térmica (más fría que el resto durante el día, más caliente durante la noche), que se subraya por el elevado contenido de agua que suelen disponer las hojas (habitualmente entre un 80 y un 400 % de su peso seco, según las especies). Esta variable supone un elemento básico para la vida de las plantas, por lo que la regulación hídrica es uno de los procesos fisiológicos más importantes en la vegetación. El aumento de la temperatura ambiente (como consecuencia de la mayor radiación) implica un aumento de la transpiración de las hojas, siempre que se encuentren bien drenadas, para mantener el equilibrio térmico. La energía liberada como flujo de calor latente, disminuye el calor sensible de las plantas, lo que explica que tiendan a estar más frías durante el día que su entorno. Este proceso se revierte durante la noche, cuando se re-emite la energía recogida de día, a la longitud de onda del térmico, lo que explica que ofrezca una mayor temperatura que las áreas limítrofes.

Este mecanismo de regulación térmica de la vegetación permite analizar su estado hídrico a partir de la información registrada en el infrarrojo térmico. Las estimaciones de evapotranspiración (*ET*) en cultivos o vegetación natural se han llevado a cabo a partir de la ecuación del balance de energía:

$$Rn = \xi ET + H + G + PH \qquad \{2.16\}$$

donde: R_N es la radiación neta; ξET es el flujo de calor latente o evapotranspiración donde ξ es el calor latente de vaporización y *ET* el flujo de agua evaporada; *H* es el flujo de calor sensible; *G* es el flujo de calor del suelo; *PH* es la energía utilizada en la fotosíntesis y en calentar la biomasa vegetal (Sánchez, 1992). De los procesos incluidos en la ecuación, sólo la *Rn* puede obtenerse en forma relativamente directa a partir de medidas de satélite (López-Baeza, 1991). Los demás términos se pueden obtener combinando con información observada en tierra. En Desbois se presenta la solución a cada uno de los términos apoyada en información proporcionada por teledetección. Otros autores proponen fórmulas alternativas, basadas también en la diferencia entre temperatura del aire (medida habitualmente a partir de estaciones meteorológicas) y temperatura del suelo (estimada por teledetección). Los resultados para estimar *ET* instantánea pueden considerarse bastante prometedores, tanto a escala regional (Magaritz *et al.*, 1990) como global (Choudhury, 1997). También se han propuesto varios métodos para mejorar la interpolación espacial de la *ET* utilizando imágenes de satélite (Sánchez y Chuvieco, 2000, fig. 2.18).

Por último, conviene recordar que las variaciones de *ET* están relacionadas, por un lado, con la propia fisiología de la planta, principalmente con su capacidad de retención de agua y geometría de las hojas (resistencia estomatal y resistencia aerodinámica). También es preciso considerar otros factores atmosféricos externos, como la humedad atmosférica, velocidad del viento, disponibilidad de luz, temperatura del aire y humedad del suelo. La humedad atmosférica reduce la *ET*, mientras el resto de los factores la aumentan.

6.3. Los suelos y el agua en el dominio térmico

Respecto a los suelos, el contenido de humedad es el factor más destacado de su conducta térmica. A mayor humedad, el suelo presentará una mayor inercia térmica, puesto que aumenta su calor específico y conductividad. Esto le lleva a presentarse más frío durante el día y más cálido durante la noche que los suelos secos.

Otros parámetros a considerar serían la densidad, calor específico y conductividad del tipo de material que forma el suelo. Diversos estudios de laboratorio han mostrado cómo el cuarzo presenta una densidad y calor específico similar a la arcilla, pero ofrece valores de conductividad mucho más elevados. Por ello, su inercia térmica es mayor, a la vez que cuenta con bajos valores de emisividad (0,90). Los suelos con alto contenido de materia orgánica ofrecen los valores más bajos de conductividad, por lo que tienden a mostrar más nítidamente las diferencias de temperatura entre el día y la noche.

De los párrafos anteriores, se deduce fácilmente que el agua posee la mayor inercia térmica. Esta resistencia a cambiar de temperatura es debida a su alta conductividad: la radiación incidente es fuertemente absorbida y transmitida a lo largo de la superficie por movimientos de convección, con lo que resulta más difícil que cambie de temperatura. Esto permite detectar con bastante facilidad plumas de agua provenientes de fuentes ajenas al entorno, como sería agua con materiales en suspensión o descargas de centrales nucleares. Asimismo, cartografiar la temperatura de la superficie marina resulta de gran interés para la detección de bancos de pesca (Cañón, 2000; Tameishi, 1991) o el estudio global del clima, tanto en lo que se refiere a tendencias promedio (calentamiento de al-

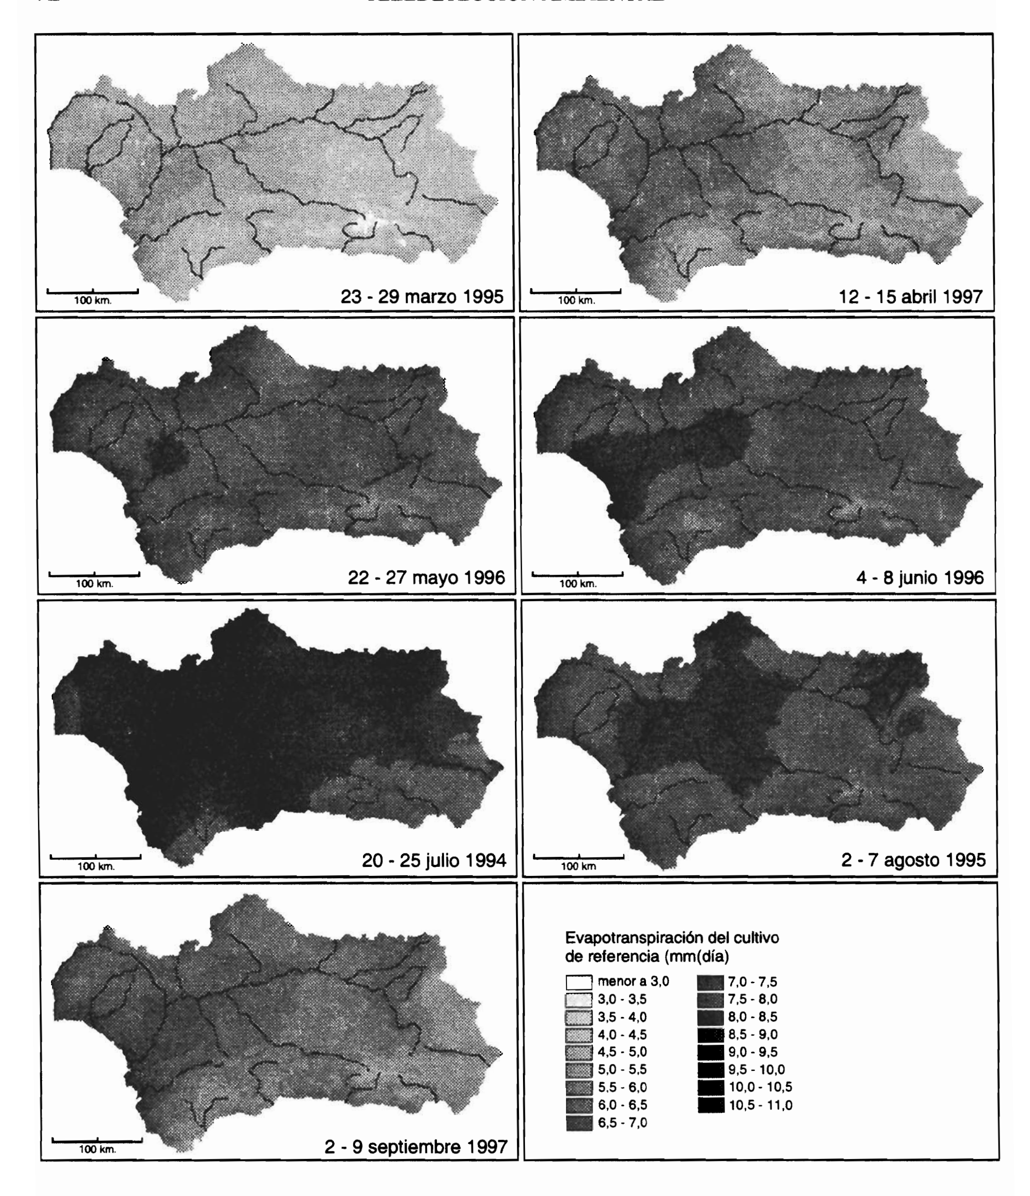


FIG. 2.18. *Estimación de la evapotranspiración del cultivo de referencia (mm/día) mediante ecuaciones de regresión múltiple a partir de datos NOAA-AVHRR (Sánchez y Chuvieco, 2000).*

gunas zonas), como a movimientos particulares de las corrientes oceánicas. Por ejemplo, la detección precoz del fenómeno del Niño, que provoca efectos de escala planetaria, se realiza a partir de sensores térmicos, ya que obedece a un calentamiento inusual de una enorme masa de agua situada sobre el Pacífico Sur (ver, entre otros: http://www.pmel.noaa.gov/tao/elnino/nino-home.html, último acceso 4-03-2008).

Volviendo a las propiedades térmicas de las cubiertas terrestres, la temperatura de la nieve está influida por el tamaño de los cristales y el contenido de agua líquida,

siendo en líneas generales muy baja. Como ya vimos, esta cubierta ofrece la mayor reflectividad en el visible, por lo que la absorción de energía es baja y tiende a registrar más bajas temperaturas que el entorno. La observación de la nieve en el térmico es de gran ayuda para diferenciar tipos y estudiar la dinámica de su cobertura, de cara a estimar volumen de agua almacenada (Ferris y Congalton, 1989).

7. La región de las micro-ondas

7.1. Características de la radiación energética en la región de las micro-ondas

La banda del espectro que se inicia en las longitudes de onda milimétricas se denomina región de las micro-ondas. Se trata de las longitudes mayores utilizadas en teledetección, si bien cuentan asimismo con otras aplicaciones civiles y militares.

La observación en esta banda del espectro es complementaria y más compleja que la realizada en las bandas ópticas o térmicas, por lo que el rango de aplicaciones es todavía inferior al registrado en éstas, si bien está aumentando notablemente en los últimos años, gracias a la creciente disponibilidad de satélites equipados con equipos de micro-ondas (ERS, Radarsat, JERS, Almaz, etc.). La virtud fundamental de esta región del espectro es ser prácticamente transparente a la influencia atmosférica, ya que se trabaja a longitudes de onda muy superiores al tamaño habitual de las gotas de agua (0,1 mm: fig. 2.19). Esto supone que pueden observarse áreas cubiertas por nubes, lo que hace a esta región espectral idónea para zonas muy lluviosas, donde la observación en otras bandas del espectro es prácticamente inviable. Por ejemplo, el radar lateral aero-transportado (SLAR), permitió completar la primera cartografía de la cuenca del Amazonas y de varios países de Centro-América, detectando recursos hídricos y mineros antes desconocidos (Henderson y Lewis, 1998).

La observación remota en la banda de las micro-ondas se realiza habitualmente con sensores activos (denominados radar: cap. 3), que no se limitan a registrar la radiación emitida por las cubiertas, sino que emiten la suya propia, recogiendo posteriormente su retro-dispersión. Esto permite una gran versatilidad a la teledetección de micro-ondas, ya que pueden observarse las cubiertas con las condiciones específicas que parezcan más convenientes para una determina aplicación.

Los sensores pasivos en esta banda se denominan radiómetros de micro-ondas. Son poco utilizados en teledetección, puesto que la emitancia de los objetos es difícilmente perceptible en esta banda. Para las longitudes de onda que comprende, se emplea la aproximación de la ley de Planck calculada por Rayleigh-Jeans (Elachi, 1987):

$$M_{n,\lambda} = \frac{2\pi kT}{\lambda^4} \qquad \{2.17\}$$

donde $M_{n,\lambda}$ corresponde a la emitancia espectral, T a la temperatura en Kelvin, y λ a la longitud de onda. Las constantes tienen el mismo significado que en {2.4}. En esta región, los valores de M_l son muy bajos, y existen frecuentes interferencias entre señales

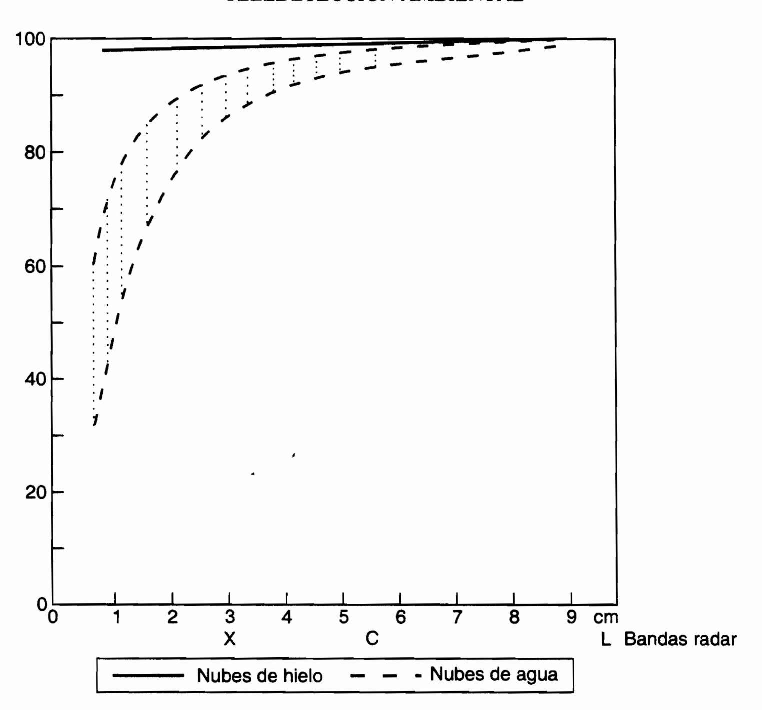


FIG. 2.19. *Transmisividad de las nubes en la región de las micro-ondas (adaptado de ESA, 1995).*

emitidas, reflejadas y transmitidas. Por ello, no es una técnica muy difundida en teledetección espacial, aunque se ha mostrado de gran interés para el estudio de capas de hielo y nieve (Kelly y Hall, 2008). La cartografía de la Antártida a partir del radiómetro ESMR del satélite Nimbus-5 (Hall y Martinec, 1985, pp. 141-149) resulta muy significativa a este respecto. Otros autores han propuesto estimar el grosor de la cobertura de nieve a partir de las diferencias de temperaturas entre dos canales de micro-ondas detectados por el mismo sensor (Chang *et al.*, 1990). En el campo de los suelos o la vegetación, se ha propuesto el empleo de estos equipos para determinar el contenido de humedad (Paloscia, 1994), aunque su limitación más importante sigue siendo la baja resolución espacial que ofrecen desde plataformas especiales.

Pese al interés de estas experiencias, el radar *(Radio Detection and Ranking)* es el sensor más importante en esta banda del espectro. Por tratarse de un haz emitido artificialmente, pueden controlarse las condiciones de adquisición: ángulo, distancia, orientación, polarización, etc. Esto facilita la interpretación posterior de la señal, si bien es una tarea compleja ante la gran cantidad de factores que intervienen en el proceso.

Cuando se emite un haz de micro-ondas desde un radar a la superficie terrestre, la mayor parte de ese haz es dispersado al contacto con ella. Según la naturaleza del sustrato, el haz principalmente se dispersa hacia la atmósfera (caso del suelo), se dispersa dentro del propio objeto (caso de la vegetación), o se refleja especularmente (caso del agua). Como es lógico, el radar sólo registrará la señal dispersada con la misma dirección del flujo incidente, por lo que se denomina retro-dispersión, σ. Según este factor, el radar registrará una señal de retorno muy distinta (fig. 2.20).

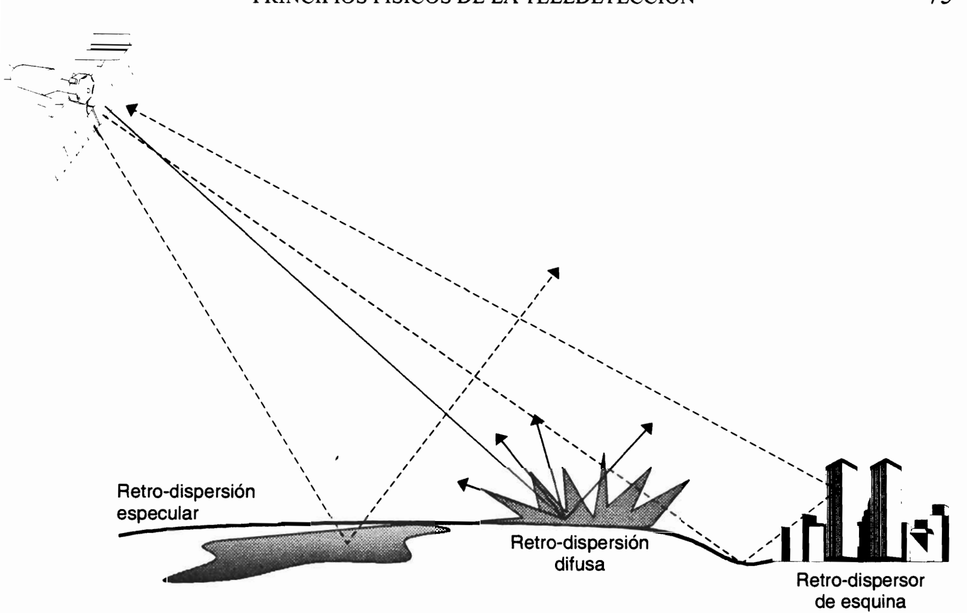


FIG. 2.20. *Distintos tipos de retro-dispersión a la señal radar (adaptado de Campbell, 1987).*

Desgraciadamente, como ocurre en otras bandas del espectro, la retro-dispersión no es única y constante para cada cubierta. Otros factores, que podríamos denominar medioambientales, influyen en la señal finalmente detectada por el sensor. En resumen, el retorno de la señal radar está influenciado por factores relacionados con la cubierta, por un lado, y con las características de la observación, por otro. Entre los primeros, los más destacados son la constante dieléctrica, y la rugosidad, mientras los segundos deben considerar la longitud de onda, el ángulo de incidencia y la polarización. Estos factores introducen una cierta variabilidad en torno al retorno característico de cada tipo de cubierta, haciendo más complicada su discriminación.

La constante dieléctrica se relaciona con la capacidad de la cubierta para almacenar y transmitir electrones. En términos generales, los materiales secos ofrecen una constante dieléctrica entre 3 y 8, mientras el agua ofrece un valor de 80. En consecuencia, la presencia de agua en el suelo o la vegetación puede alterar significativamente el pulso de retorno. Por esa razón, la vegetación —casi siempre cargada de humedad— tiende a ofrecer un pulso de retorno mayor que los suelos secos. También son buenos conductores las superficies metálicas, que ofrecen valores de retro-dispersión bastante elevados. Esta variable no es constante para todas las longitudes de onda, siendo mayor, generalmente, cuanta mayor longitud consideremos.

La rugosidad del terreno es un factor clave en la retro-dispersión, siendo directamente proporcionales. Las superficies más rugosas, entonces, aparecen más claras en la señal radar, y más oscuras las más lisas. El concepto de rugosidad no sólo depende de la estructura de la superficie, sino también de la longitud de onda y del ángulo de observación. En longitudes cortas una superficie relativamente llana puede aparecer como rugosa, mientras se comporta como lisa en longitudes mayores (fig. 2.21). Por su parte, la intensidad de retorno es menor, cuando mayor sea el ángulo de incidencia

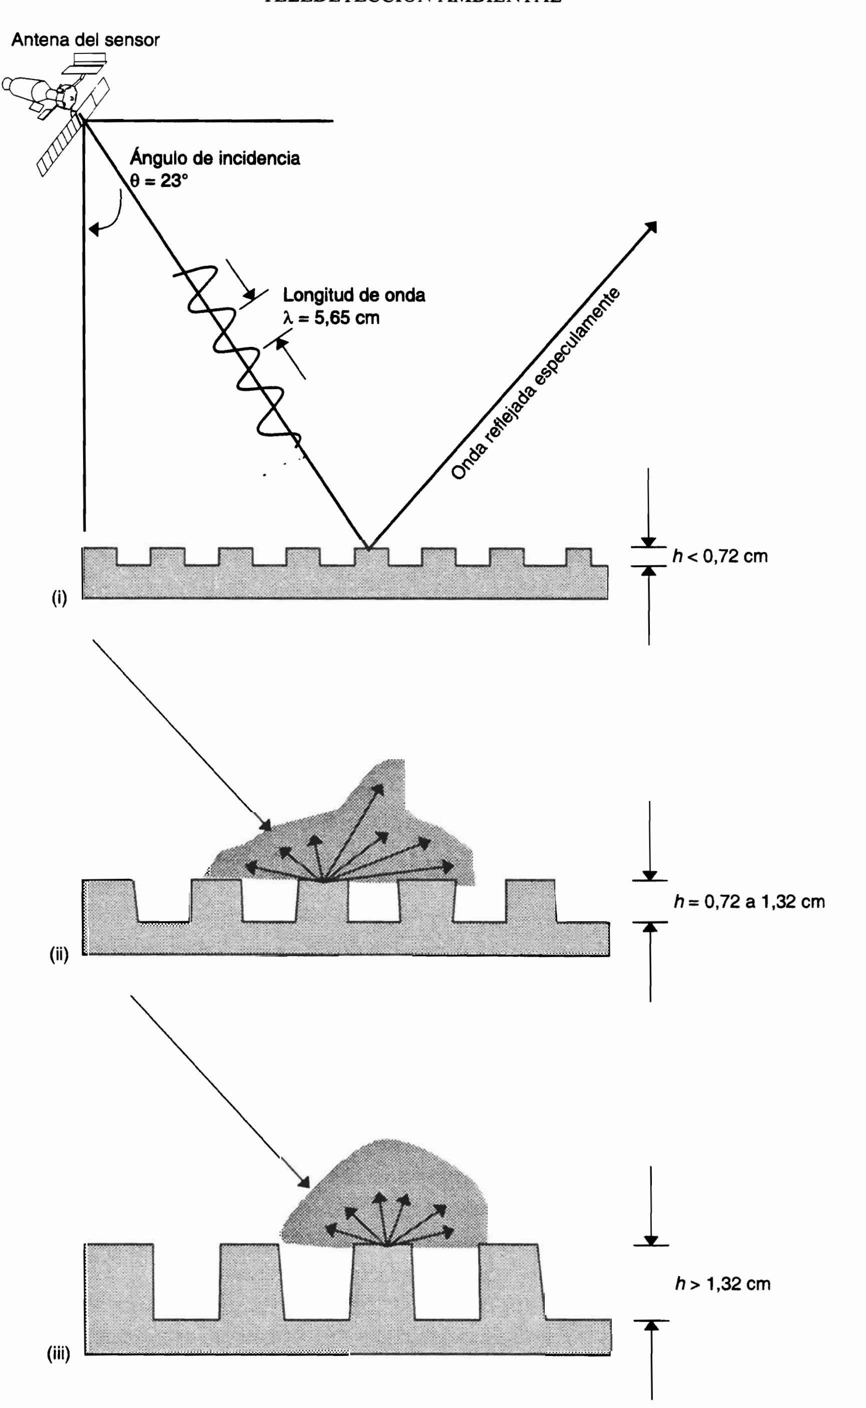


FIG. 2.21. *La retro-dispersión del terreno está en función de la longitud de onda y la variación altitudinal de la cubierta: (i) superficie suave, nula señal de retorno; (ii) superficie moderadamente rugosa, retorno medio; (iii) superficie rugosa, retorno intenso (adaptado de Lillesand y Kiefer, 1994).*

de la señal radar. Esta relación se concreta gracias al criterio de Rayleigh, que considera una cubierta como rugosa si:

$$s_s \geq \frac{\lambda}{8} \cos\theta \qquad \{2.18\}$$

donde s_h es la desviación típica de las variaciones de altura de la superficie; λ la longitud de onda de observación, y θ el ángulo de incidencia. En pocas palabras, esto indica que a igual rugosidad del terreno, éste aparecerá tanto más liso cuanto se trabaje a longitudes de onda mayores, y/o con ángulos de incidencia mayores (esto es, en una observación más oblicua). Esta relación es muy importante, ya que en una superficie que aparece como rugosa, la dispersión de retorno se dirige en todas las direcciones y el sensor capta una fuerte señal. En cambio, si la cubierta aparece lisa la reflexión tiende a ser especular y la señal de retorno puede llegar a ser prácticamente nula. Este es el caso de las masas de agua en calma, que aparecen con tonos oscuros en una imagen radar, como puede observarse en la figura 2.22, que recoge una imagen del radar avan-



FIG. 2.22. *Imagen adquirida por el radar del satélite europeo Envisat sobre la desembocadura del Ganges, mostrando los efectos de las severas inundaciones de julio de 2007 (Cortesía ESA: http://earth.esa.int/).*

TABLA 2.2. *Bandas de frecuencia habitualmente utilizadas en micro-ondas*

Denominación	*Anchura (cm)*		*Valor típico*	*Anchura (GHz)*	
Ka	0,75	1,10			
K	1,10	1,67	1,0	10,9	36
Ku	1,67	2,40			
X	2,40	3,75	3,0	5,75	10,90
C	3,75	7,50	5,6	3,90	5,75
S	7,50	15,00	10,0	1,55	3,90
L	15,00	30,00	23,0	0,39	1,55
P	30,00	100,00	70,0	> 0,39	

zado del satélite Envisat sobre las inundaciones que afectaron el Sureste de la India en el verano de 2007. Calcuta aparece en el suroeste de la imagen y Dhaka, la capital de Bangla Desh en el centro-este. Ambas pueden distinguirse nítidamente por los tonos claros, que indican una mayor rugosidad del terreno.

Respecto al segundo grupo de factores que citábamos en la retro-dispersión, relacionados con las condiciones de observación, los más destacados son la longitud de onda, el ángulo de incidencia y la polarización. Al igual que hicimos en el espectro óptico, en esta región podemos distinguir una serie de bandas de observación con características equiparables. Siguiendo una terminología extraída, en buena parte, de las aplicaciones militares que dieron origen al radar, las bandas de micro-ondas se denominan por una letra, y suelen acotarse por rangos de frecuencia (normalmente GHz: tabla 2.2). Ya hemos indicado que la banda de observación tiene un importante efecto sobre la constante dieléctrica y la rugosidad, así como la capacidad de obtener información del sustrato. Las más comunes, como veremos en el capítulo 3, son las denominadas *C* y *L*, situadas, respectivamente, en torno a los 5,7 y los 23 cm.

El ángulo de incidencia también hemos visto que modifica la rugosidad aparente del terreno, así como las características geométricas de la imagen radar resultante. Las observaciones más oblicuas tenderán a crear condiciones de reflexión especular, y por tanto retornos al radar muy bajos. Otro aspecto interesante relacionado con el ángulo de incidencia —así como la banda de observación— es la capacidad de obtener información del terreno a cierta profundidad. Si se combina un ángulo de incidencia bajo con una longitud de onda larga, el pulso del radar puede penetrar a una cierta profundidad, consiguiéndose interesante información sobre fondos de vegetación o suelos (fig. 2.23). Por ejemplo, los equipos en bandas cortas (*X*), sólo recogerán retorno de la capa más superficial de la vegetación, mientras los situados en bandas largas (*L*), podrán observar también características del sotobosque. El análisis simultáneo de varias bandas, en consecuencia, permite detectar información de gran interés sobre la composición vertical de la vegetación (Dobson, 2000; Ranson *et al.*, 2001).

Conviene tener en cuenta que el ángulo de incidencia cambia en la dirección perpendicular a la trayectoria del avión o satélite; en definitiva, no es constante para cada punto de la imagen, ya que la observación que realizan los equipos radar es lateral, como veremos en el capítulo 3. También del ángulo de incidencia depende la información morfológica que proporciona el radar. Con ángulos altos, el efecto de sombra al

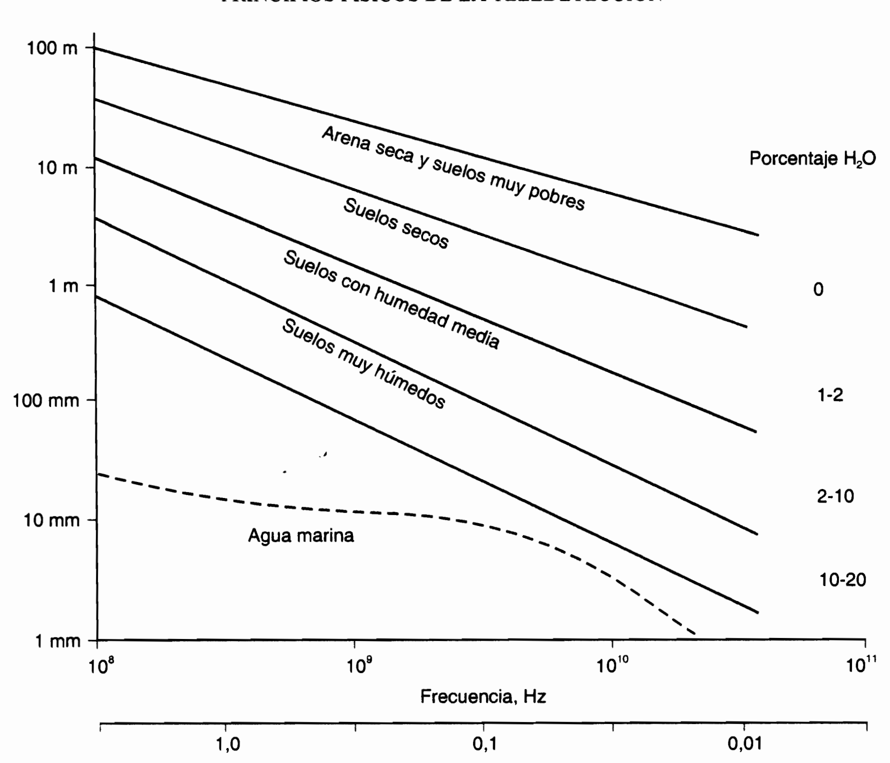


FIG. 2.23. *Relación entre humedad del suelo y capacidad de penetración del radar a distintas longitudes de onda (adaptado de Trevett, 1986).*

radar se realza notablemente, aunque también lo hacen las deformaciones geométricas. Esta sombra es relativa a la orientación de la topografía frente a la antena, de ahí que si se varía el ángulo de incidencia pueden conseguirse efectos estereoscópicos. A partir de esa reconstrucción tri-dimensional se realza notablemente el estudio de la geología y geomorfología local (ver, más adelante, la fig. 3.29).

Por último, la polarización refiere a la forma en la cual son transmitidas y recibidas las señales del radar. Una señal polarizada indica que su vibración se restringe a una dirección determinada. Las dos formas más importantes son la polarización semejante, cuando la señal emitida y la recibida tienen la misma polarización (Horizontal-Horizontal o Vertical-Vertical), y la cruzada, cuando varía la polarización entre la señal emitida y la recibida (Horizontal-Vertical o Vertical-Horizontal). La dirección con que la señal está polarizada influye en el flujo de retorno, puesto que el eco del radar es selectivo a la dirección de propagación. Se ha comprobado en muchos materiales que la polarización proporciona información de interés para discriminar una cubierta, por lo que varios radares espaciales permiten recoger los flujos de retorno con distintas polarizaciones (ver fig. 4*).

7.2. Características de la vegetación en la región de las micro-ondas

En lo que afecta a la vegetación, la rugosidad es un elemento fundamental en la señal de retorno. La rugosidad es muy dependiente del tamaño, forma, orientación y número de hojas. A partir de la observación en una sola banda resulta, en consecuencia, muy complicado distinguir tipos de vegetación. En varios proyectos de inventario forestal, se ha puesto en evidencia la dificultad para separar, por ejemplo, coníferas de caducifolias, tanto en banda L (Deane, 1980), como en banda S, X y C, como consecuencia de la gran variabilidad de coeficientes de retro-dispersión en coníferas (Hyyppa y Hallikainen, 1996; Leckie, 1990).

Respecto a la conductividad, la constante dieléctrica es bastante alta y constante para la mayor parte de las masas vegetales, incrementándose con el mayor contenido de humedad durante la época de crecimiento. Cuando la vegetación pierde vigor o el aporte del suelo es mayor, la constante dieléctrica disminuye drásticamente. De aquí se deduce que es posible obtener información sobre la humedad del sustrato vegetal (Leblon *et al.*, 2002), siempre y cuando se trabaje con ángulos de incidencia altos (Paloscia, 1994).

En una experiencia piloto para medir la humedad de una superficie de praderas, se observaron mejores ajustes trabajando en bandas cortas (banda X), y con ángulos de incidencia de 30°, con los que se logró un coeficiente de determinación (r^2) del 90 %. Para ángulos más bajos, hasta de 0°, sólo se consiguieron ajustes del 50 %. Un efecto similar, aunque con peores correlaciones, se observó en la banda C (Gogineni *et al.*, 1991).

La profundidad de penetración en masas vegetales es dependiente de la longitud de onda a la que se trabaje, así como de las condiciones de humedad del sustrato y de la polarización. Resulta mayor a longitudes largas (banda L, en donde influye notablemente las condiciones del sustrato), y con señales de polarización semejante (HH o VV), mientras se reduce a longitudes cortas (banda X, más sensible a la geometría y orientación de las hojas) o con señales de polarización cruzada (HV o VH). De acuerdo a algunos autores, en la banda X puede estimarse la rugosidad de la vegetación, en la C la biomasa de la hoja y en la L la biomasa de la madera (Curran y Foody, 1994*a*; Dobson, 2000). Hasta ahora la mayor parte de las misiones espaciales sólo disponían de una banda radar (caso del ERS o del Radarsat), por lo que no ha resultado posible aplicar algunas técnicas de interpretación multifrecuencia. Las experiencias se han centrado en radares aeroportados (como el Airsar, operado por el JPL), o en algunas misiones del *Space Shuttle* (Dobson, 2000).

7.3. Características del suelo y el agua en la región de las micro-ondas

De los párrafos anteriores se deduce que los suelos rugosos y secos tendrán un mayor coeficiente de retro-dispersión y, por tanto, aparecerán con tonos claros en las imágenes radar. Si la señal se reduce, manteniendo otras condiciones constantes, se tratará normalmente de suelos más húmedos. En suelos secos la capacidad de penetración del radar aumenta hasta llegar a varios metros si la longitud de onda es suficientemente larga (fig. 2.23). Cuando se presenten mezclas de vegetación y suelo, lo más probable es que la señal de retorno mezcle también ambas cubiertas, complicándose

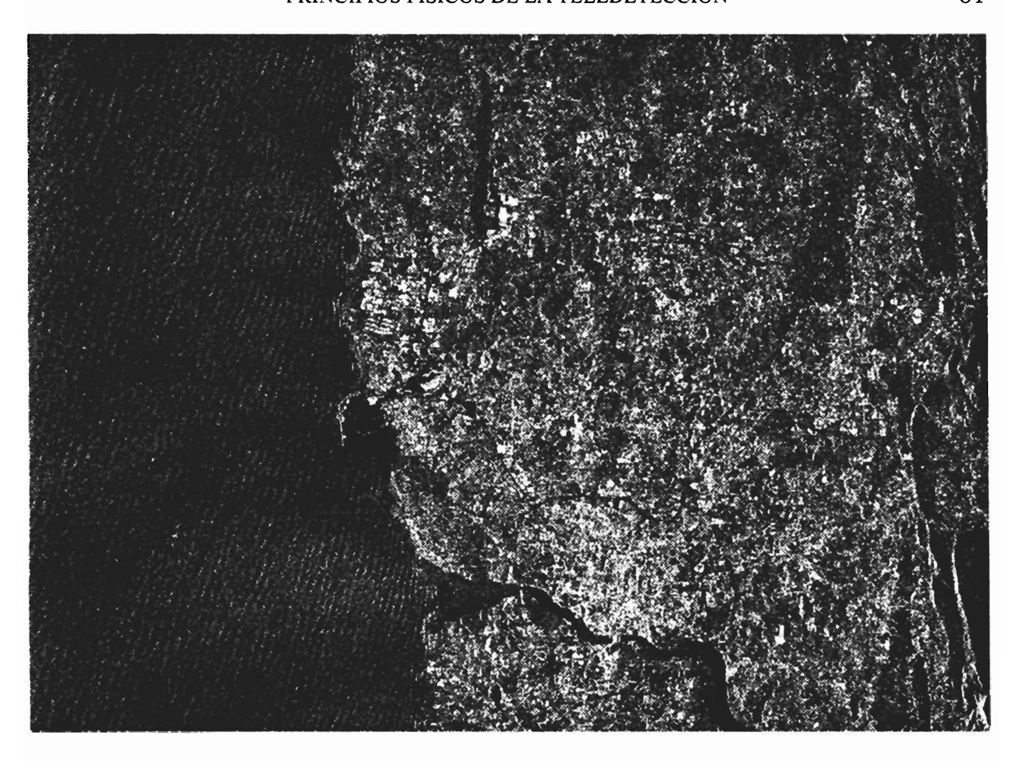


FIG. 2.24. *Imagen de los alrededores de la ciudad de Oporto (Portugal) adquirida por el radar del Envisat en enero de 2004 que muestra rasgos urbanos y oleaje (Cortesía ESA: http://earth.esa.int/).*

bastante la interpretación de la señal. En experimentos con micro-ondas aeroportadas, se ha observado que las bandas cortas (banda C) facilitan mejor información sobre la humedad de la cubierta vegetal (al tener menor capacidad de penetración), mientras en banda L puede detectarse más la vegetación del suelo (Paloscia, 1994).

Los núcleos de población, altamente rugosos a longitudes largas, también aparecen con tonos claros, lo que permite discriminarlos frente a los espacios cultivados limítrofes (Meliá y Sobrino, 1987).

En cuanto al agua, la región de las micro-ondas proporciona una cierta capacidad de penetración, siempre que el ángulo de incidencia sea bajo y se trabaje con longitudes de onda largas. El agua, casi siempre refleja especularmente el pulso recibido, con lo que el retorno es bastante bajo. Ahora bien, si existe una cierta rugosidad superficial, por ejemplo oleaje, puede manifestarse en la imagen radar, siempre que el ángulo de incidencia sea bajo (fig. 2.24). Esta aplicación es muy útil para detectar anomalías en la superficie, por ejemplo las causadas por descargas incontroladas de petróleo (ver fig. 3.30). A partir de variaciones menores en la altura del oleaje, medido con otros equipos de micro-ondas (como altímetros o dispersómetros de vientos), puede obtenerse información de los fondos oceánicos, y, a partir de la rugosidad superficial, los vectores de dirección y velocidad del viento (fig. 2.25).

Respecto al hielo y nieve, el pulso de retorno es muy dependiente de las condiciones del material. La edad, composición y compacidad de la capa de hielo, su rugosi-

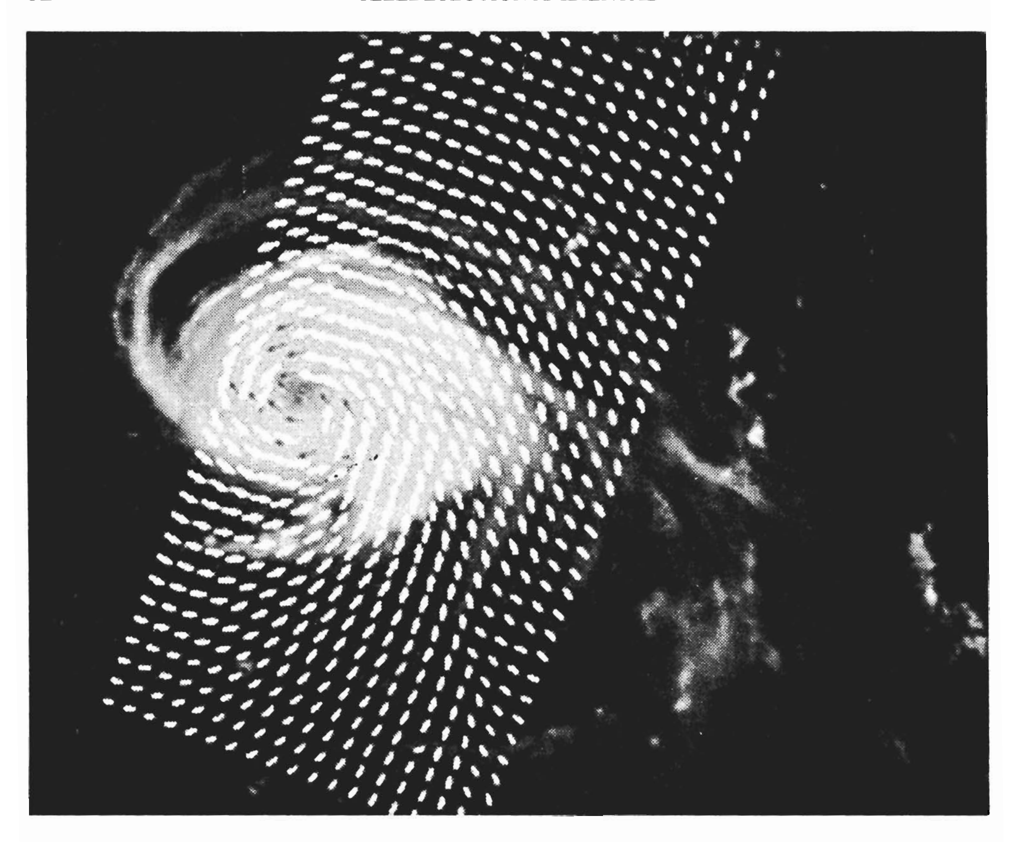


FIG. 2.25. *Imagen del satélite Meteosat del huracán Emily (agosto de 1993) a la que se ha superpuesto un campo de vientos generado por el dispersómetro del ERS-1.*

dad, geometría interna y temperatura son factores destacados en el coeficiente de retro-dispersión finalmente detectado por el sensor.

8. Interacciones de la atmósfera con la radiación electro-magnética

Hasta aquí hemos considerado la interacción de la radiación electro-magnética con las diversas coberturas terrestres como si este proceso se desarrollara en el vacío. Obviamente, esta suposición es falsa, puesto que entre el sensor y la superficie terrestre se interpone la atmósfera, que interfiere de formas diversas con el flujo radiante.

Como es sabido, la atmósfera se compone de gases —nitrógeno, oxígeno, argón, vapor de agua y dióxido de carbono— y aerosoles. Entre esos componentes, el dióxido de carbono, ozono y vapor de agua son los principales responsables de la interacción con la energía electro-magnética. Su efecto es triple: por un lado, absorben energía incidente en determinadas bandas del espectro, lo que limita la observación espacial a aquellas bandas en donde esta absorción es menos intensa; dispersan determinados flujos, y emiten otros, como todo cuerpo caliente. Estos procesos introducen

modificaciones, en ocasiones muy severas, en la radiación originalmente propagada entre la cubierta y el sensor, por lo que es preciso tenerlos en cuenta de cara a obtener una medición más precisa de las características del territorio observado. Comentaremos con más detalle cada uno de esos efectos.

8.1. Absorción atmosférica

La atmósfera se comporta como un filtro selectivo a distintas longitudes de onda, de tal forma que en algunas bandas del espectro elimina prácticamente cualquier posibilidad de observación remota. Los principales causantes de esta absorción son:

— Oxígeno atómico (O_2), que filtra las radiaciones ultravioleta por debajo de 0,1 µm, así como pequeños sectores en el infrarrojo térmico y las micro-ondas.
— Ozono (O_3), responsable de la eliminación de la energía ultravioleta, inferior a 0,3µm, así como en un sector de las micro-ondas (en torno a 27 mm).
— Vapor de agua (H_2O), con una fuerte absorción en torno a 6 mm, por encima de 27 mm y otras menores entre 0,6 y 2 µm.
— Dióxido de Carbono (CO_2), que absorbe en el infrarrojo térmico (> 15 µm), con importantes efectos en el infrarrojo medio, entre 2,5 y 4,5 µm.
— Aerosoles atmosféricos, que principalmente absorben en el espectro visible (ver fig. 3*).

Como consecuencia de esta absorción, la observación espacial se reduce a determinadas bandas del espectro, conocidas como ventanas atmosféricas, en donde la transmisividad de la atmósfera es suficientemente alta (fig. 2.26). Las principales ventanas atmosféricas son las siguientes: (i) espectro visible e IRC, situada entre 0,35 y 1,35 µm; (ii) varias en el SWIR de 1,5 a 1,8 µm y de 2,0 a 2,4 µm, (iii) en el IRM: 2,9 a 4,2 µm, y de 4,5 a 5,5 µm; (iv) en el IRT, entre 8 y 14 µm, y (v) en las micro-ondas, por encima de 20 mm, en donde la atmósfera es prácticamente transparente.

Estas ventanas atmosféricas son idóneas para realizar procesos de teledetección, por lo que el diseño de los sensores espaciales tiende a ajustarse a estas bandas, evitan-

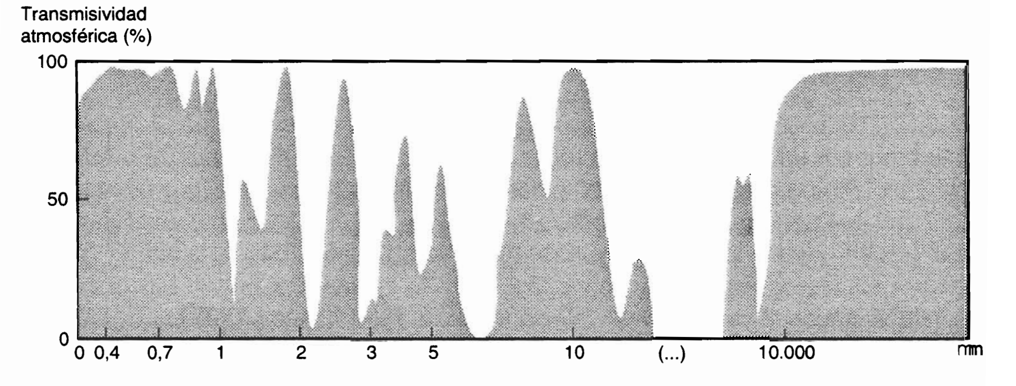


Fig. 2.26. *Transmisividad de la atmósfera a distintas longitudes de onda.*

do interferencias extrañas al fenómeno que pretende observarse, salvo la presencia de nubes, que absorben en todo el espectro óptico.

Por el contrario, si se pretende observar la atmósfera en lugar de la superficie terrestre, las bandas de observación más convenientes son, precisamente, aquéllas en donde la absorción atmosférica es alta. Bajo este enfoque, lo que se pretende es derivar a partir de teledetección estimaciones de la concentración en la atmósfera de distintos gases, analizando sus espectros de absorción ((Sobrino, 2000, cap. 5). La importancia que estos componentes gaseosos tienen sobre el clima del planeta ha llevado a enfatizar estos estudios de teledetección atmosférica en los últimos años, especialmente en el marco de los programas para el estudio del cambio climático global (Chuvieco y Justice, 2008; Kaufman *et al.*, 1990; King *et al.*, 1999). Especial importancia, en este contexto, han tenido los estudios mediante teledetección de emisiones procedentes de incendios forestales (Palacios-Orueta *et al.*, 2005; Van der Werf *et al.*, 2006).

Puesto que los satélites meteorológicos están especialmente interesados en las condiciones de la atmósfera, habitualmente incluyen bandas de observación en zonas de alta absorción de gases, sobre todo del vapor de agua (caso del Meteosat o GOES, con bandas de observación entre 5,7 y 7,1 μm). El mismo enfoque se aplicó al diseño de los sensores TOMS *(Total Ozone Mapping Spectrometer)* a bordo de varios satélites norteamericanos, y GOME *(Global Ozone Monitoring Experiment)* y GOMOS *(Global Ozone Monitoring by Occultation of Stars)*, incluido en los satélites europeos ERS-2 y Envisat, que fueron ideados para cartografiar la capa de ozono, por lo que observan la región del ultravioleta, en donde este gas ofrece una alta absorción.

Cuando la variable de interés no ofrece una absorción total a una determinada región del espectro, como es el caso de los aerosoles, suelen utilizarse otras técnicas de análisis, por ejemplo la comparación multibanda con referencia a superficies de baja radiancia (agua profunda, zonas en sombra), si bien resultan más precisos los métodos basados en observación multiangular (lo que permite estimar el espesor óptimo atmosférico) o multipolarización (King *et al.*, 1999). En el primer capítulo cabría citar las observaciones pioneras del ATSR *(Along Track Scanning Radiometer)* a bordo del ERS, y las mas recientes del POLDER (en el satélite japonés ADEOS) y el MISR (en la carga útil del satélite Terra), que más tarde comentaremos.

8.2. Dispersión atmosférica

La dispersión de la radiación electro-magnética es causada por la interacción entre ésta y las partículas atmosféricas en suspensión. La reflexión consiguiente a ese choque supone un aporte adicional a la radiancia proveniente de la superficie terrestre (luz atmosférica), lo que implica una reducción de la radiancia directa y un aumento de la difusa. Puesto que las partículas atmosféricas son muy variables en el tiempo y en el espacio, resulta muy complejo cuantificar su influencia final en la imagen adquirida por el sensor. Pese a ello, convendrá tener en cuenta este factor, especialmente cuando se pretenda convertir los valores digitales de la imagen a parámetros físicos (6.2.3), o se aborden estudios multitemporales (7.3).

Los principales causantes de la dispersión atmosférica son los aerosoles y las gotas de agua. Los aerosoles son partículas en suspensión de origen muy diverso: oceáni-

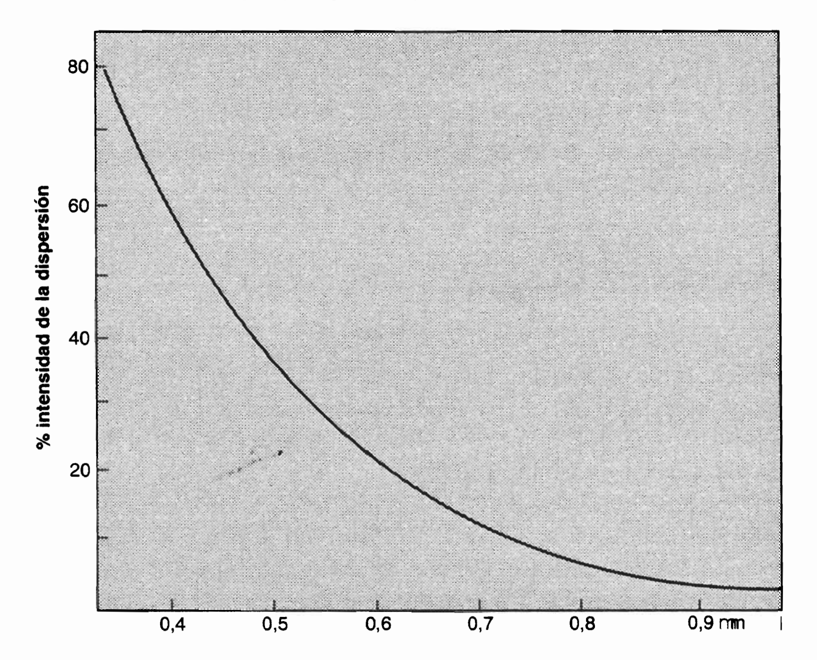


FIG. 2.27. *Dispersión atmosférica a distintas longitudes de onda (adaptado de Campbell, 1987).*

co —debidas al movimiento de las aguas—, o continental, polvo en suspensión o partículas emitidas por combustión. Tienen una notable importancia en el clima terrestre, tanto por su efecto absorbente como dispersor, modificando las propiedades de las nubes, el albedo terrestre y la química atmosférica (King *et al.*, 1999). En función de su origen y características poseen muy variados tamaños, lo que implica distintos tipos de dispersión, ya que ésta es muy dependiente de su diámetro. De esta forma, se habla de dispersión *Rayleigh*, causada por partículas muy pequeñas, de diámetro inferior a la longitud de onda; dispersión *Mie*, cuando se trata de partículas de diámetro similar a la longitud de onda, y de dispersión no selectiva, cuando se mencionan las partículas de mayor tamaño.

La dispersión *Rayleigh* afecta a las longitudes de onda más cortas, que son mucho más dispersadas que el resto (fig. 2.27). Es la más conocida y la de mayor influencia en teledetección. Causa, por ejemplo, el color azul del cielo. En fotografía aérea, es muy claro su efecto por el tono azulado que presentan los fotogramas cuando se realizan desde cierta altura. Cualquier observador distante puede comprobar este resultado, especialmente en los meses de verano, cuando se difumina el paisaje al divisarlo a largas distancias (calima).

En cuanto a la dispersión *Mie*, es también dependiente de la longitud de onda, si bien en menor grado que la anterior. Aerosoles y polvo atmosférico son los principales responsables de este tipo de dispersión, aunque también está presente en incendios forestales o en brumas costeras. Por último, la dispersión no selectiva afecta por igual a diversas longitudes de onda. Por esta razón, las nubes o nieblas tienden a aparecer blancas, ya que dispersan por igual toda la luz visible.

Los procesos de dispersión son muy complejos y difíciles de cuantificar en la

imagen resultante. Normalmente no se dispone de datos coetáneos a la adquisición de ésta, por lo que la corrección atmosférica se basa en relaciones entre elementos de la propia imagen (6.2.3). Esta estimación puede ser burda en algunos casos, y dificulta, en última instancia, el uso de las imágenes adquiridas por sensores espaciales como medida cuantitativa de parámetros biofísicos.

8.3. Emisión atmosférica

El efecto de emisión atmosférica resulta fundamental en el trabajo dentro del infrarrojo térmico, si se pretenden obtener mediciones de temperatura a partir de las imágenes espaciales. Al igual que cualquier cuerpo por encima del cero absoluto, la atmósfera emite energía, por lo que ese parámetro debe considerarse para separarlo de la emitancia espectral proveniente del suelo.

Las correcciones atmosféricas en el térmico (efectos de absorción y emisión) se han abordado habitualmente analizando la absorción diferencial de la atmósfera en dos bandas contiguas del infrarrojo térmico. Se denominan algoritmos de ventana partida *(split window)*, que tendremos ocasión de comentar más adelante (6.2.4). También puede estimarse el componente atmosférico a partir de la observación desde dos ángulos distintos (nadiral y oblicuo), por ejemplo, a partir de imágenes del ATSR (Sobrino, 2000, pp. 184 y ss).

CAPÍTULO 3

SENSORES Y SATÉLITES DE TELEDETECCIÓN

«Tras de un amoroso lance,
y no de esperanza falto,
volé tan alto, tan alto,
que le di a la caza alcance.»

SAN JUAN DE LA CRUZ,
Poesía Completa

1. Tipos de sensores

Como ya se indicó en el primer capítulo, un sistema de teledetección requiere, al menos, tres componentes: foco energético, superficie terrestre y sensor. Del primero y segundo se trató en el epígrafe sobre principios físicos. En éste se aborda el estudio de las características del sensor y de la plataforma que lo sustenta.

Entre las variadas formas de clasificar los sensores remotos, una de las más habituales considera su procedimiento de recibir la energía procedente de las distintas cubiertas. En este sentido, se habla de dos tipos de sensores: 1) pasivos, cuando se limitan a recibir la energía proveniente de un foco exterior a ellos, y 2) activos, cuando son capaces de emitir su propio haz de energía. Estos últimos son, lógicamente, más flexibles, puesto que no dependen tanto como los primeros de las condiciones exteriores al sistema sensor-Tierra.

Una ulterior clasificación entre los sensores pasivos, considera su procedimiento para grabar la energía recibida. De acuerdo a ello, puede hablarse de sensores fotográficos, óptico-electrónicos y de antena. Los primeros resultan muy familiares, puesto que se basan en las mismas técnicas aplicadas en la fotografía convencional. El resto son menos conocidos por el gran público, si bien sistemas similares se utilizan rutinariamente: cámaras digitales, *scanners* en exploración médica, y radiómetros de micro-ondas en radio difusión.

En cuanto a los sensores activos, el equipo más conocido es el radar, bastante utilizado en aplicaciones militares, así como en control del tráfico aéreo. El radar trabaja en la región de las micro-ondas. Por su parte, el lídar opera con luz polarizada (láser) en el espectro óptico.

Antes de comentar con mayor detenimiento cada uno de estos sensores, conviene analizar algunos conceptos previos que nos sirven para valorar la utilidad de la información que proporcionan, y que resultarán útiles para planificar posteriormente su empleo en distintos problemas medioambientales.

2. **Resolución de un sistema sensor**

De acuerdo con algunos autores, podemos definir la resolución de un sistema sensor como su habilidad para discriminar información de detalle (Estes y Simonett, 1975). Esta definición engloba varios aspectos que merecen un comentario más minucioso. Por un lado, se habla de resolución de un sistema sensor, indicando que este concepto se refiere al conjunto del equipo y no a cada una de sus partes. Dicho de otra forma, la resolución de un sensor depende del efecto combinado de sus distintos componentes. Una mejora en la lente —por ejemplo— no supondrá necesariamente adquirir fotografías con mayor resolución, si no se acompaña de una película de mayor sensibilidad, o no se modifican las condiciones de exposición.

Los términos de la definición «discriminar» e «información de detalle» merecen también una breve reflexión. Ambos son relativos al propósito y al entorno geográfico del proyecto que se esté abordando. La discriminación considera la capacidad de distinguir un objeto de otros. Esa distinción puede referirse a una simple determinación de que está ahí (detección) o a una delimitación precisa de su contorno (identificación). Lógicamente, la segunda tarea requiere mayor resolución espacial que la primera (Robin, 1998), ya que un objeto puede detectarse por sus efectos en la radiancia global observada (por ejemplo, el brusco aumento de temperatura que implica una erupción volcánica), pero para identificarlo con detalle (localizar con precisión el cráter) será necesario que el mínimo objeto que identifica el sistema sea mucho más pequeño que el tamaño del propio cráter.

En cuanto al significado de «información de detalle», conviene considerar que se refiere no sólo al detalle espacial que proporciona el sensor, sino también al número y anchura de las bandas del espectro que alberga, a su cadencia temporal, y a su capacidad para distinguir variaciones en la energía que detecta (Campbell, 1996). Todas estas dimensiones son de interés para discriminar cubiertas o establecer modelos de significado físico. En definitiva, el concepto de resolución implica diversas manifestaciones, las más habituales en la literatura especializada han sido la espacial, espectral, radiométrica y temporal. En los últimos años, a éstas podemos añadir también la resolución angular, que haría referencia a la capacidad de un sistema de observar el mismo objeto desde distintas posiciones. A continuación, comentaremos con más detalle cada una de ellas.

2.1. Resolución espacial

Este término designa al objeto más pequeño que puede ser distinguido sobre una imagen. En un sistema fotográfico, suele medirse como la mínima separación a la cual los objetos aparecen distintos y separados en la fotografía. Se mide en milí-

metros sobre la foto —o metros sobre el terreno—, y depende de la longitud focal de la cámara y de su altura sobre la superficie. En los sensores óptico-electrónicos, se prefiere utilizar el concepto de campo de visión instantáneo (*instantaneous field of view*, IFOV). El IFOV se define como la sección angular, medida en radianes, que observa el sensor en un momento determinado. En lugar de esta definición, habitualmente suele utilizarse la distancia sobre el terreno que corresponde a ese ángulo (d), que puede calcularse a partir de él, conociendo la distancia del suelo al sensor (h):

$$d = 2\ h \tan (\text{IFOV}/2) \qquad \{3.1\}$$

asumiendo que se trate de una observación vertical. La distancia del IFOV proyectada al suelo se corresponde con el tamaño de la mínima unidad de información incluida en la imagen, que se denomina píxel (del inglés *picture element*). Ésta es la medida más generalizada de resolución espacial, aunque también se emplean otros términos más complejos, como ERE *(effective resolution element)* o EIFOV *(effective instantaneous field of view)*, que consideran la señal detectada como una función modulada compuesta (Townshend, 1980).

La resolución espacial de un sensor depende de varios factores, como son la altura orbital, la longitud focal, y el número de detectores. En cuanto a los sensores de antena, su resolución depende del tamaño de la misma, de la altura de la plataforma, y del ángulo de incidencia. Cuanto mayor sea el radio, y menor la altitud y la longitud de onda, la resolución será tanto más detallada.

El rango de la resolución espacial de los sensores de observación terrestre en funcionamiento cubre niveles de detalle bastante diversos (fig. 3.1). Los satélites que cuentan con mayor resolución ofrecen un detalle espacial próximo a 1 m^2, mientras los de recursos naturales, diseñados para adquirir información sobre áreas muy heterogéneas, suelen contar con resoluciones próximas a los 25 × 25 m. Otro grupo de sensores, orientado hacia aplicaciones más globales, cuentan con píxeles de un tamaño comprendido entre 300 y 1.000 m de lado. Finalmente, los sensores que presentan menor resolución espacial son los satélites meteorológicos de órbita geoestacionaria (Meteosat, GOES, GMS), con píxeles de hasta 5 km de lado. En el futuro cercano está previsto continuar con el lanzamiento de satélites de muy alta resolución, la mayor parte de los cuales son propiedad de consorcios comerciales (IKONOS, Quickbird), e incluso mejorar su resolución actual hasta los 40 cm. Como ya vimos en el primer capítulo, esta mayor disponibilidad de imágenes de alta resolución permitirá ampliar al rango actual de aplicaciones de esta técnica, entrando en dominios anteriormente reservados a los medios aéreos de observación.

La resolución espacial tiene un papel protagonista en la interpretación de la imagen, por cuanto marca, de alguna forma, el nivel de detalle que ésta ofrece. Parece obvio decir que sólo serán identificables sobre la imagen elementos que superen el tamaño de varios píxeles, si bien pueden detectarse rasgos de tamaño similar o incluso más pequeño al del píxel cuando exista suficiente contraste radiométrico (ver cap. 5).

En consecuencia, la resolución espacial está estrechamente ligada con la escala de trabajo y con la fiabilidad finalmente obtenida en la interpretación. Cuanto menor sea el tamaño del píxel, menor también la probabilidad de que éste sea un com-

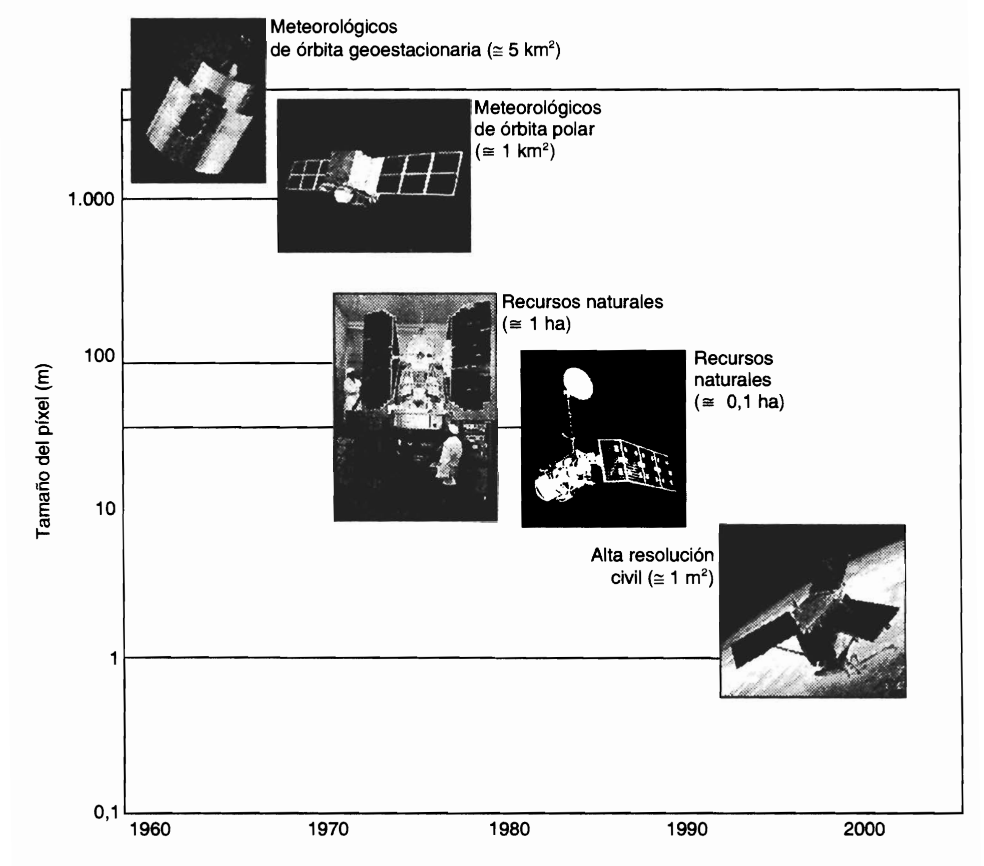


FIG. 3.1. *Tendencias en la resolución espacial.*

puesto de dos o más cubiertas fronterizas. Un píxel mixto estará definido por una señal intermedia a las distintas cubiertas que lo componen. En consecuencia, puede no asemejarse a ninguna de ellas, lo que dificultará notablemente su correcta identificación (fig. 3.2). Sin embargo, en el caso concreto de algunas cubiertas, singularmente las urbanas, se ha comprobado que incrementar la resolución espacial puede afectar negativamente a la interpretación, cuando ésta se realiza digitalmente, al incrementar excesivamente la heterogeneidad interna en algunas categorías (Cushnie, 1987; Green, 2000; Townshend y Justice, 1981). En lo que se refiere a análisis visual, queda fuera de toda duda el interés de mejorar la resolución espacial para facilitar una interpretación más certera de la imagen (Hopkins *et al.*, 1988).

2.2. RESOLUCIÓN ESPECTRAL

Indica el número y anchura de las bandas espectrales que puede discriminar el sensor. En el capítulo anterior se puso en evidencia el interés de contar con información multiespectral; esto es, de registrar simultáneamente el comportamiento de

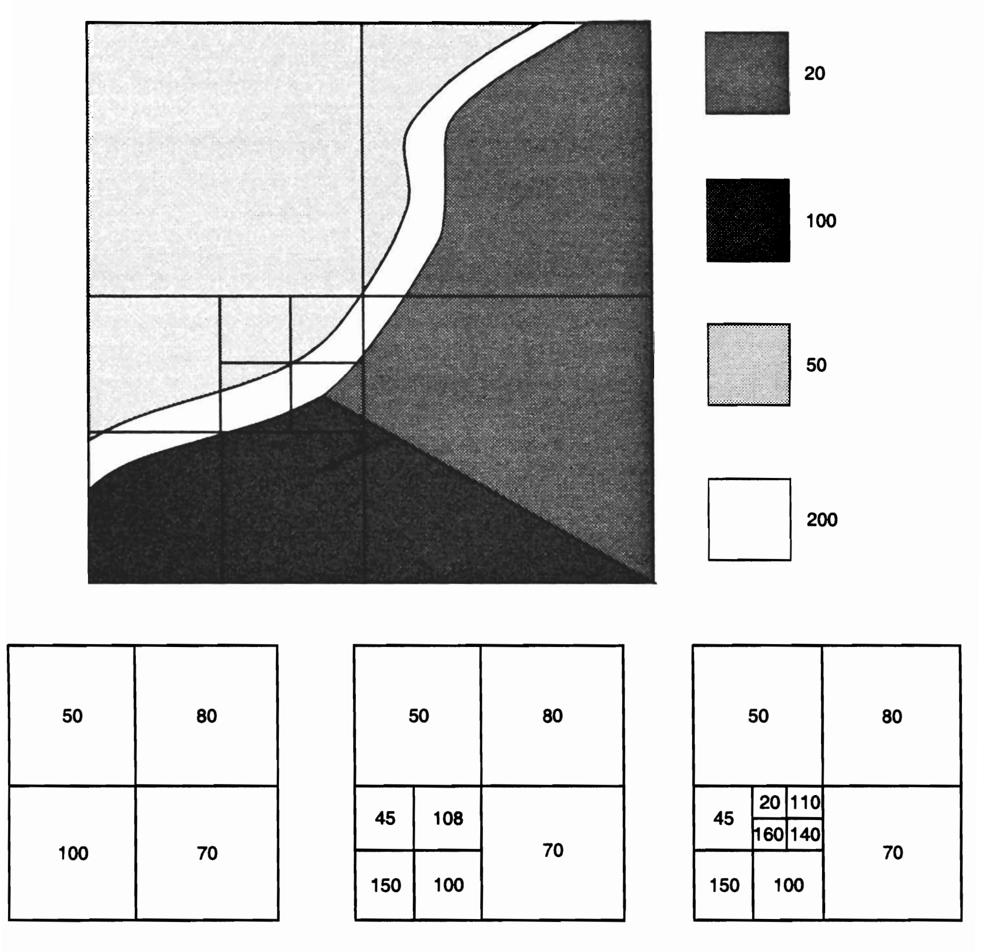


FIG. 3.2. *Al aumentar la resolución espacial, la señal recogida por el sensor resulta más cercana a la radiancia real de la cubierta.*

los objetos en distintas bandas del espectro (fig. 3.3). En este sentido, un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral de las distintas cubiertas. A la vez, conviene que esas bandas sean suficientemente estrechas, con objeto de recoger la señal sobre regiones coherentes del espectro. Bandas muy amplias suponen registrar un valor promedio, que puede encubrir la diferenciación espectral entre cubiertas de interés (fig. 3.4).

Entre los sensores espaciales, la menor resolución espectral corresponde al radar y a los sistemas fotográficos. El primero trabaja normalmente en un solo canal, mientras la fotografía puede ofrecer películas pancromáticas, infrarrojo b/n, color natural o infrarrojo color. Por el contrario, los sensores óptico-electrónicos ofrecen un mayor rango de bandas, desde las 3 de los primeros SPOT-HRV (verde, rojo e infrarrojo cercano) hasta las 220 ofrecidas por el sensor Hyperion, a bordo del satélite EO-1. Hasta hace pocos años, la observación de un número elevado de bandas espectrales (lo que se denomina habitualmente teledetección hiperespectral) estaba

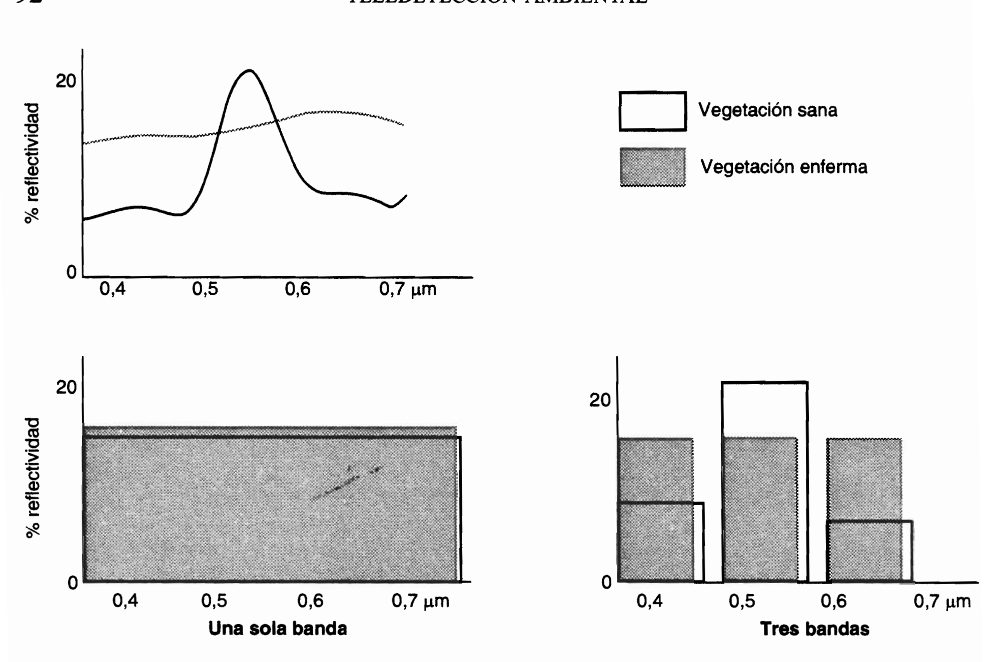


FIG. 3.3. *Efecto de la resolución espectral en la discriminación de cubiertas. Una banda pancromática sólo recoge una señal promedio, que no permite distinguir entre vegetación sana y enferma, mientras esta distinción es factible con una observación multiespectral.*

reducida a sensores aeroportados. Sin embargo, a partir del lanzamiento del MODIS, Hyperion, MERIS y CHRIS-PROBA, se han enriquecido notablemente las posibilidades de estas técnicas, abriéndose un futuro muy prometedor en el análisis de los recursos terrestres, como luego tendremos ocasión de comentar (7.1.6).

La elección del número, anchura y localización de las bandas que incluye el sensor está estrechamente relacionada con los objetivos de su diseño. Para un sensor dedicado a detectar incendios, podría ser con situar una sola banda en el IRM, puesto que ahí es muy claro el contraste con las cubiertas vecinas. La mayor parte de los sensores requieren un mayor número de bandas para mejorar la discriminación de las cubiertas de interés, ya que a mayor resolución espectral, podrán reconocerse mejor los rasgos de absorción específicos de cada cubierta (Kruse *et al.*, 1993*b*).

2.3. RESOLUCIÓN RADIOMÉTRICA

Hace mención a la sensibilidad del sensor, esto es, a su capacidad para detectar variaciones en la radiancia espectral que recibe. En el caso de los sistemas fotográficos, la resolución radiométrica del sensor se indica por el número de niveles de gris distintos que aparecen en la fotografía. Para los equipos digitales, la imagen se codifica en un formato binario, por lo que la resolución radiométrica suele identificarse con el rango posible de valores que almacena el sensor (fig. 3.5), medido como el número de bits que necesita cada valor numérico para almacenarse. Por ejemplo, los

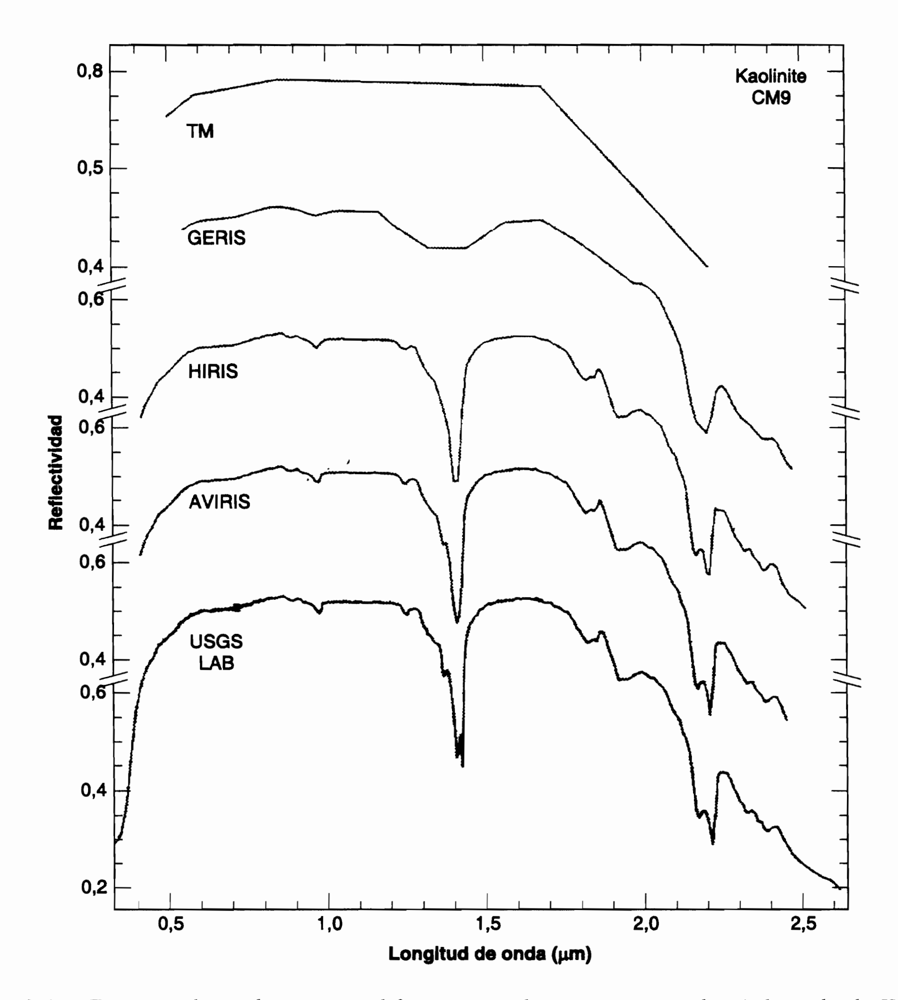
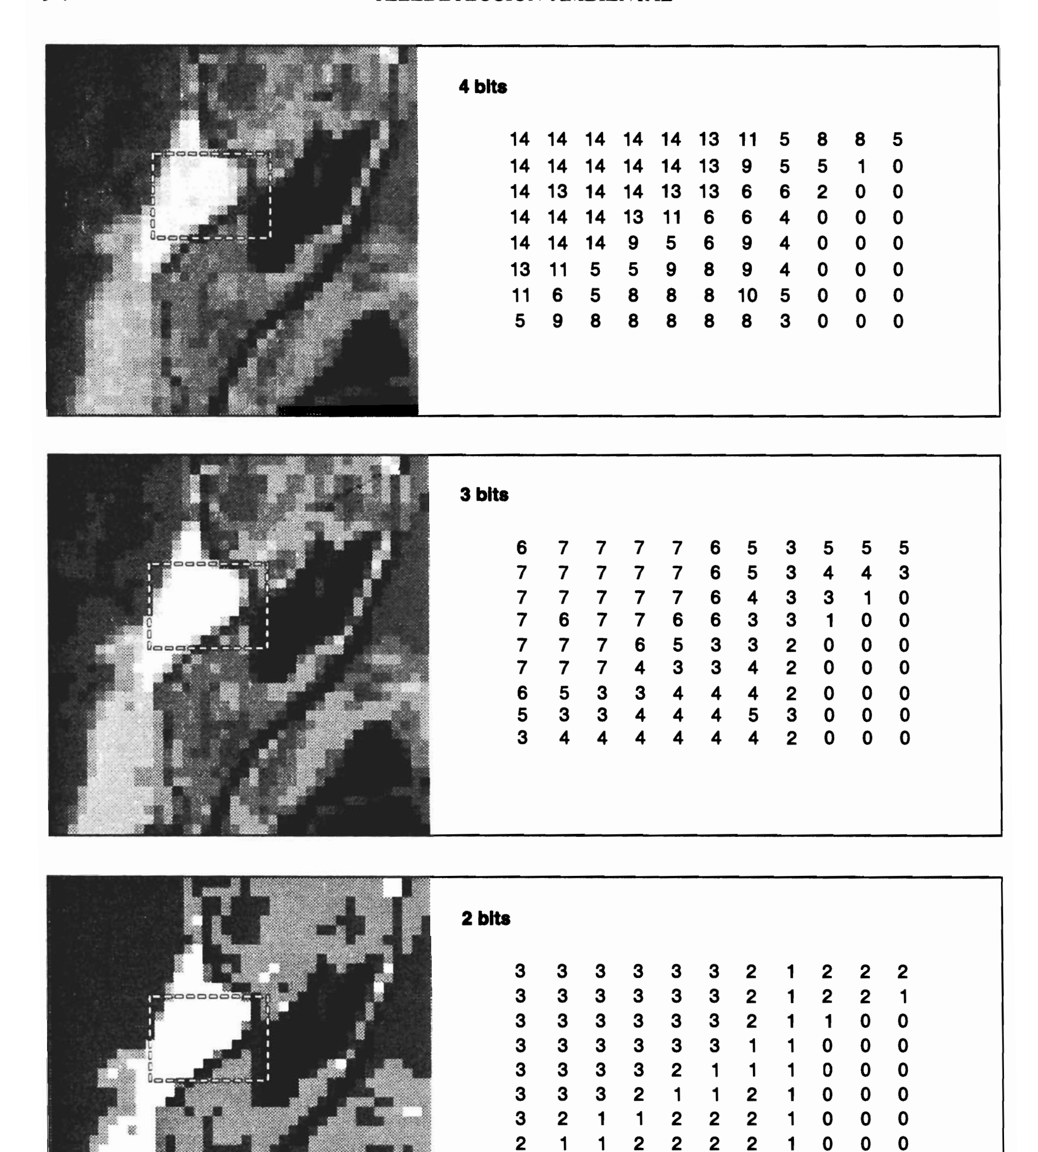


FIG. 3.4. *Espectro de caolinita para diferentes resoluciones espectrales (adaptado de Kruse* et al., *1993).*

primeros Landsat llevaban incorporado un sensor que ofrecía un rango de 128 niveles de codificación (7 bits, $2^7 = 128$) por píxel, con 64 (6 bits) para la banda del infrarrojo cercano. Actualmente, la mayor parte de los sistemas ofrecen 256 niveles por píxel (8 bits), aunque hay algunos que extienden ese rango notablemente, como el NOAA-AVHRR, que trabaja con 1.024 niveles (10 bits), el IKONOS o Quickbird, que codifican hasta 2048 valores (11 bits), y el MODIS y los radares del ERS y Radarsat, que discriminan hasta 65.536 valores (16 bits). Ésta será seguramente la resolución estándar para los futuros sensores de observación terrestre.

La resolución radiométrica, como ocurre con las dos anteriormente vistas, resulta de notable ayuda en la interpretación de imágenes, especialmente cuando realizamos análisis digital. Es preciso considerar que el número de niveles de gris que son capaces de discriminar nuestros ojos no excede de 64, mientras las tonalidades de color no superan las 200.000. Algunos autores estiman que basta con 16 niveles



4 bits

14	14	14	14	14	13	11	5	8	8	5
14	14	14	14	14	13	9	5	5	1	0
14	13	14	14	13	13	6	6	2	0	0
14	14	14	13	11	6	6	4	0	0	0
14	14	14	9	5	6	9	4	0	0	0
13	11	5	5	9	8	9	4	0	0	0
11	6	5	8	8	8	10	5	0	0	0
5	9	8	8	8	8	8	3	0	0	0

3 bits

6	7	7	7	7	6	5	3	5	5	5
7	7	7	7	7	6	5	3	4	4	3
7	7	7	7	7	6	4	3	3	1	0
7	6	7	7	6	6	3	3	1	0	0
7	7	7	6	5	3	3	2	0	0	0
7	7	7	4	3	3	4	2	0	0	0
6	5	3	3	4	4	4	2	0	0	0
5	3	3	4	4	4	5	3	0	0	0
3	4	4	4	4	4	4	2	0	0	0

2 bits

3	3	3	3	3	3	2	1	2	2	2
3	3	3	3	3	3	2	1	2	2	1
3	3	3	3	3	3	2	1	1	0	0
3	3	3	3	3	3	1	1	0	0	0
3	3	3	3	2	1	1	1	0	0	0
3	3	3	2	1	1	2	1	0	0	0
3	2	1	1	2	2	2	1	0	0	0
2	1	1	2	2	2	2	1	0	0	0
1	2	2	2	2	2	2	1	0	0	0

FIG. 3.5. *Niveles de gris y digitales correspondientes a tres resoluciones radiométricas.*

por color (4.096 tonalidades) para garantizar un análisis visual adecuado (Beaven, 1988), por lo que parece superfluo contar con 256 valores digitales por banda (16,8 millones en una combinación coloreada de 3 bandas). Sin embargo, cuando la interpretación es digital, el ordenador aprovecha todo el rango disponible, con lo que una mayor resolución radiométrica puede permitir discriminar objetos con niveles muy

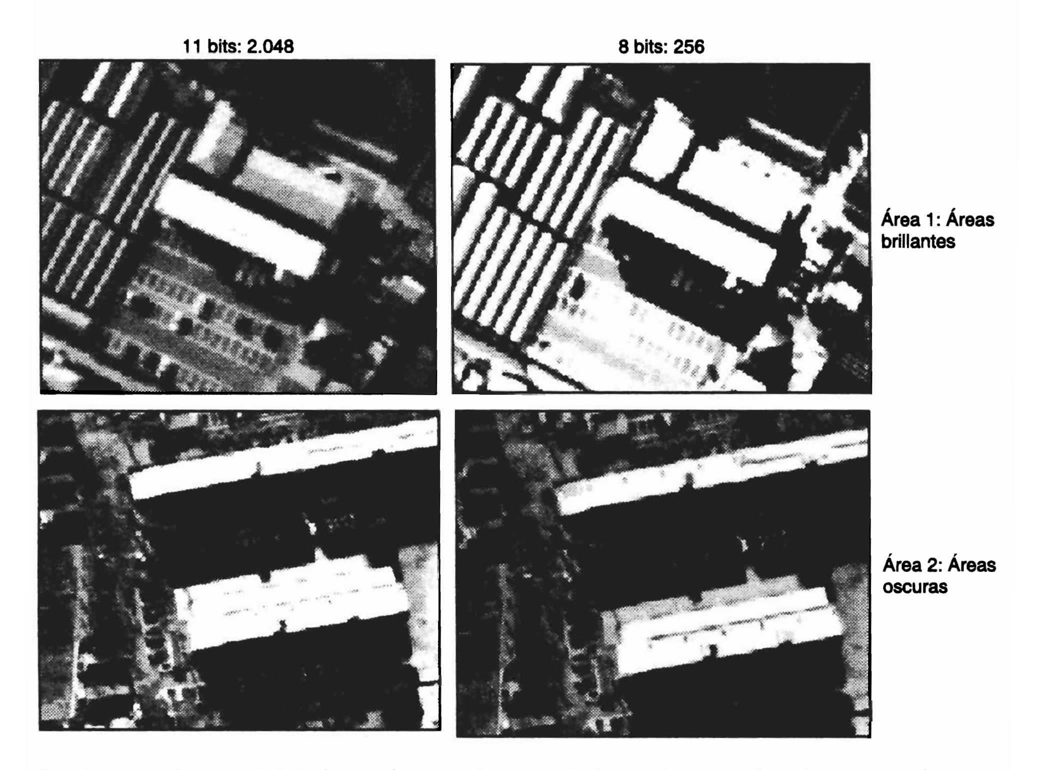


FIG. 3.6. *Imágenes IKONOS que ilustran el interés de la resolución radiométrica para discriminar tipos de superficie. En el fragmento superior sólo se distinguen los dos tipos de tejado en la imagen de mayor resolución radiométrica, mientras en la inferior se distinguen los coches en sombra. Cortesía Indra Espacio.*

similares de reflectividad, que no serían separables con otros sensores menos sensibles (fig. 3.6).

2.4. RESOLUCIÓN TEMPORAL

Este concepto alude a la frecuencia de cobertura que proporciona el sensor. En otras palabras, refiere a la periodicidad con la que éste adquiere imágenes de la misma porción de la superficie terrestre. El ciclo de cobertura está en función de las características orbitales de la plataforma (altura, velocidad, inclinación), así como del diseño del sensor, principalmente del ángulo total de abertura (tamaño de la imagen). Conviene tener en cuenta que la resolución temporal efectiva dependerá también de las condiciones atmosféricas, ya que con sensores ópticos o térmicos no podremos observar áreas cubiertas por nubes, por lo que en algunas zonas la cadencia de imágenes útiles puede ser notablemente más baja que el ciclo de adquisición del sensor. Para obviar de alguna manera estos problemas, los sensores más modernos incluyen la capacidad de observación no vertical (lo que se denomina sensores «enfocables»), facilitando así la adquisición de datos sobre una zona de interés desde una órbita próxima.

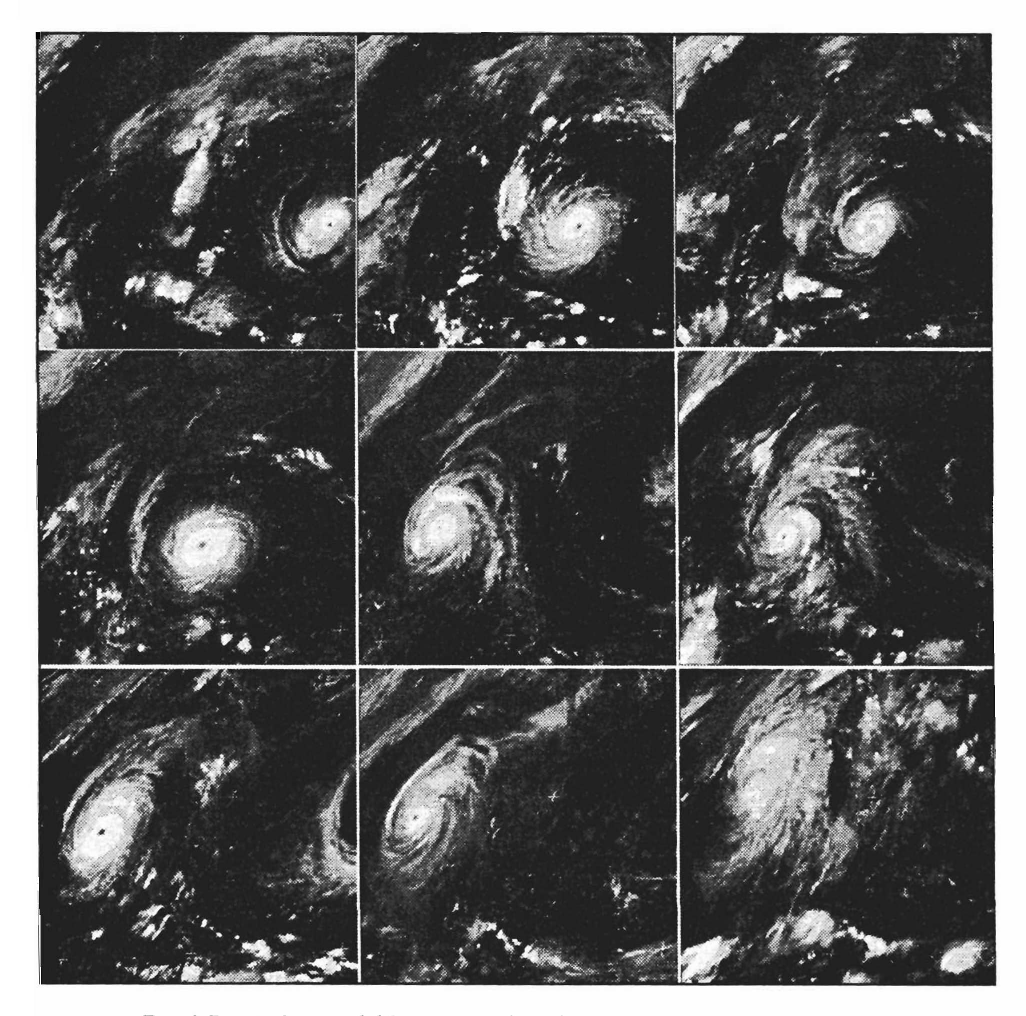


FIG. 3.7. *Imágenes del Meteosat sobre el huracán Andrew (Cortesía ESA).*

La cadencia temporal de los sistemas espaciales varía de acuerdo a los objetivos fijados para el sensor. Los satélites meteorológicos están obligados a ofrecer una información en períodos cortos de tiempo, ya que se dedican a observar un fenómeno muy dinámico (fig. 3.7). De ahí que la red de satélites geoestacionarios (Meteosat, GOES, GMS) proporcione una imagen cada 30 minutos. Esta información se complementa con la obtenida a partir de los satélites meteorológicos de órbita polar, como el NOAA, que facilita imágenes cada 12 horas. Por el contrario, los satélites de recursos naturales ofrecen una cadencia mucho menor: entre los 16 días del Landsat y los 31 días del ERS.

2.5. Resolución angular

Es un término relativamente reciente, que refiere a la capacidad de un sensor para observar la misma zona desde distintos ángulos (Diner *et al.*, 1999: fig. 3.7). Tradicionalmente, se ha asumido que las cubiertas presentan una reflectividad lambertiana, lo que implica que ofrecerían una señal similar independientemente del ángulo con que se observan. En la práctica no es así, especialmente para algunas superficies que presentan fuertes efectos de reflectividad bidireccional. Una manera de modelar estos efectos es observar la cubierta desde distintas posiciones, facilitando así su mejor caracterización. También la observación multiangular resulta de gran interés para estimar algunas variables atmosféricas, ya que al variar el ángulo de mira se está observando la superficie con distinto espesor atmosférico, variando en consecuencia los procesos de absorción y dispersión.

Hasta hace pocos años no había sensores disponibles que tuvieran esta capacidad de observación multiangular, por lo que los estudios sobre direccionalidad se basaban bien en análisis con radiómetros de laboratorio, bien en sensores de amplio campo de barrido, como el NOAA-AVHRR, que observan la superficie con distintos ángulos según la posición de la órbita del satélite (en el caso del AVHRR el ciclo se repite cada 9 días). Ahora bien, esta última solución no es la más adecuada, pues puede haber severos cambios entre pasadas diarias del satélite. Por ello, se han diseñado sensores que específicamente poseen capacidad de observación simultánea en varios ángulos. Éste es el caso del ATSR-2, lanzado en 1995 a bordo del ERS-2, el POLDER, instalado en el satélite japonés ADEOS en 1997, y el MISR, incluido sobre la plataforma Terra desde 1999. De ellos, el más sofisticado es el último, que facilita nueve ángulos de observación, casi simultáneos, de la misma zona, además en varias longitudes de onda.

2.6. Relaciones entre los distintos tipos de resolución

Conviene aclarar que estos cuatro aspectos de la resolución están íntimamente relacionados. A mayor resolución espacial, disminuye habitualmente la temporal, y es previsible que se reduzca también la espectral. El principal problema se encuentra en la transmisión de las imágenes a la superficie terrestre y su posterior tratamiento. El aumento en cualquiera de los cuatro tipos de resolución significa también un incremento considerable del volumen de datos a procesar, tanto por el sensor como por la estación receptora, así como variaciones notables del precio (fig. 3.8). Por esta razón, los primeros Landsat —dotados de resolución espacial, espectral y radiométrica media— podían disponer de un sistema de grabación a bordo, que les permitía adquirir imágenes de áreas no cubiertas por la red de antenas receptoras. Al mejorar la resolución espacial, espectral y radiométrica con un nuevo sensor, los Landsat-4 y 5 ya precisaban estar constantemente conectados a una red de satélites de comunicaciones (denominados TDRSS), a través de los cuales enviaban las imágenes a las antenas receptoras. En caso de otras plataformas, como el satélite europeo ERS, sólo se registra información en el radio cubierto por las antenas receptoras, de ahí que no haya sido posible disponer de da-

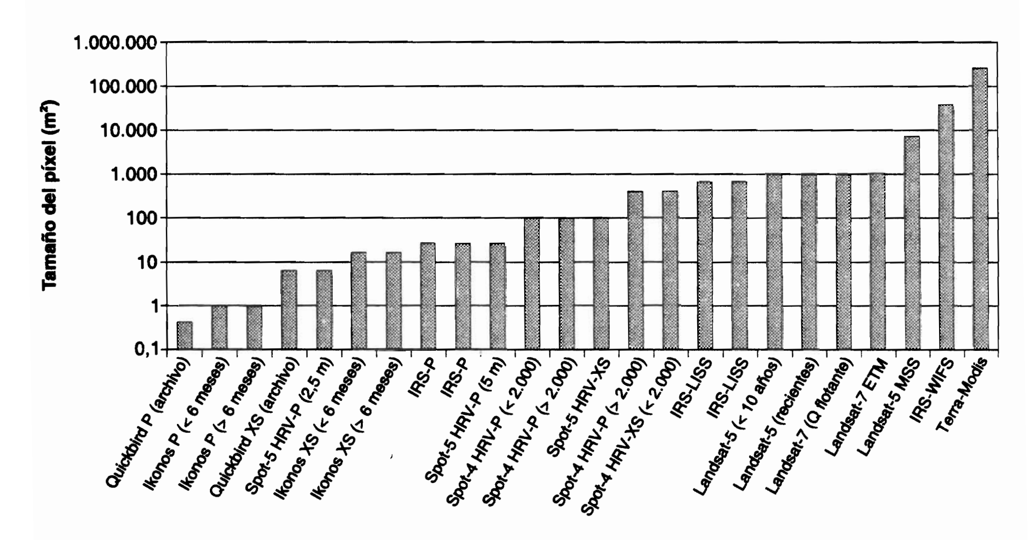


FIG. 3.8. *Resoluciones espaciales de los sensores de teledetección más utilizados (la escala vertical es lagarítmica).*

tos, de modo rutinario, de algunas zonas del mundo para las que no existían acuerdos de recepción.

Puesto que los diferentes tipos de resolución están relacionados, cada sistema de teledetección ofrece unas características particulares en función de los fines para los que se diseña. Si está orientado a la detección de fenómenos efímeros en el tiempo, deberá realzarse su cobertura temporal, aun a costa de perder resolución espacial, como ocurre con los satélites meteorológicos. Si, por el contrario, el sensor se orienta a exploración minera, el detalle espacial y espectral resulta más importante, reduciéndose entonces su ciclo temporal: un solo sistema no puede cubrir todas las expectativas.

Estos párrafos pueden contribuir a aclarar un aspecto de la resolución muchas veces malentendido. Con frecuencia se identifica la calidad del sensor con su resolución espacial, lo cual es acertado sólo en algunas aplicaciones (por ejemplo, catastro urbano o rural). Por el contrario, en otras será más acuciante mejorar otros tipos de resolución, como la temporal o espectral. Por ejemplo, la detección de incendios forestales activos o la evaluación de inundaciones no tendrían validez con sensores muy precisos espacialmente, pero que ofrecieran una imagen mensual, ya que entonces las estimaciones carecerían de interés práctico. Por esta razón, es cada vez más frecuente el uso de satélites meteorológicos —que tienen buena resolución temporal— para aplicaciones terrestres que no estaban contempladas en su diseño original (estimación de cosechas o seguimiento de la deforestación, por citar dos casos). Otras aplicaciones de la teledetección deben enfatizar la resolución espectral: por ejemplo, cuando se trate de discriminar cubiertas con un comportamiento radiométrico muy similar, sólo divergente en bandas muy particulares del espectro. La exploración minera requiere con frecuencia este tipo de sensores, que permiten también discriminar fiablemente diferentes cultivos o rendimientos.

3. Sensores pasivos

Los sensores pasivos se limitan a recoger la energía electro-magnética procedente de las cubiertas terrestres, ya sea ésta reflejada de los rayos solares, ya emitida en virtud de su propia temperatura. De acuerdo a nuestra previa clasificación, puede establecerse una división en estos sensores en función del procedimiento que emplean para recibir la radiación procedente de los objetos. Antes se aludía a los sensores fotográficos, óptico-electrónicos y de antena. En el primer grupo estarían las cámaras analógicas; en el segundo, los exploradores de barrido y de empuje, y las cámaras de vídeo, mientras los sensores pasivos de antena se conocen con el nombre de radiómetros de micro-ondas.

3.1. Cámaras analógicas

Hasta hace pocos años, las cámaras analógicas eran el medio más utilizado de teledetección aérea, si bien se van sustituyendo paulatinamente por cámaras digitales de alta resolución, con niveles de precisión geométrica y resolución similares. En lo que se refiere a teledetección desde satélite, las cámaras analógicas siempre estuvieron bastante limitadas, ya que la cantidad de película que podían cargar estas misiones las hacía de vida muy efímera. Como es sabido, una cámara fotográfica registra la energía reflejada por un objeto sobre emulsiones fotosensibles, con el apoyo de un sistema óptico que permite controlar las condiciones de exposición. Dentro de esta configuración básica, pueden establecerse numerosas variantes, en función de cuatro elementos: tipo de película, número de objetivos, ángulo de observación y altura de la plataforma.

Respecto al tipo de película, el más empleado en teledetección aérea es el film pancromático (blanco y negro), en el cual se recoge todo el espectro visible sobre una sola emulsión. En la película en color, se mezclan distintas capas foto-químicas, cada una de las cuales es sensible a una banda del espectro visible, por lo que la discriminación de los objetos resulta más atinada. Menos conocidos en nuestro país son los filmes en infrarrojo blanco y negro —que recogen en tonos de gris la radiación correspondiente al infrarrojo cercano—, y en infrarrojo color, también denominado falso color, en donde se desplaza la escala de color natural, situándose entre el verde y el infrarrojo cercano.

En cuanto al número de objetivos, puede tratarse de una cámara mono o multibanda, según albergue una o varias regiones del espectro simultáneamente. En este segundo caso, la observación múltiple puede realizarse con dos modalidades: incorporando varios objetivos —cada uno de ellos con un filtro apropiado— en una sola cámara, lo que permite impresionar la misma imagen en diversas bandas del espectro; o bien, ensamblando varias cámaras sobre el mismo soporte, cada una de ellas con filtros y filmes apropiados, con lo que se obtendrían simultáneamente distintas fotografías de la misma zona.

En lo que atañe al ángulo de observación, conviene anotar la diferencia entre fotografía vertical, tomada perpendicularmente al terreno (con ±5° de desviación permitida), y fotografía oblicua, con un ángulo de visión sensiblemente inferior a

90°. La primera se emplea, con el debido recubrimiento, para la restitución fotogramétrica, así como en estudios temáticos muy variados. La fotografía oblicua tiene principalmente un fin estético, aunque también puede reportar interesantes conclusiones para el estudio del relieve o los asentamientos humanos, entre otras facetas de interés científico.

Por último, la altura de observación permite distinguir entre fotografía aérea y espacial. Desde el punto de vista de su aplicación a estudios de medio ambiente, las diferencias más significativas entre ambas afectan a su resolución espacial, nitidez, cobertura del terreno y precisión geométrica. Las dos primeras son favorables a la fotografía aérea, y las dos últimas a las cámaras espaciales.

De acuerdo al contenido de esta obra, nos centraremos en el análisis de los programas de exploración fotográfica desde plataformas espaciales. Históricamente estas experiencias fueron las pioneras de teledetección desde el espacio, asociadas principalmente a misiones tripuladas. Las primeras fotografías espaciales de observación civil se obtuvieron durante la misión Mercury-4, a las que siguieron las adquiridas por las cápsulas Gemini y Apollo en los primeros años sesenta. En un primer momento estas fotografías se adquieren casi espontáneamente, pero más tarde, y ante la calidad de los resultados, se comenzaron a diseñar proyectos dirigidos específicamente a la observación de los recursos naturales. Este fue el caso de la misión Gemini GT-4 que incluyó el primer experimento programado de teledetección espacial, concretamente para aplicaciones geológicas.

A esta tentativa siguieron otras de gran interés, a bordo de diversas misiones Apollo (fig. 3.9), que sirvieron para preparar el terreno a otros programas dedicados exclusivamente a la observación terrestre. En este sentido, conviene destacar el papel del laboratorio espacial tripulado *Skylab*, activo, con diversas tripulaciones, durante 1973. En esta plataforma se incluyó un programa de observación terrestre bautizado como EREP (*Earth Resources Experiment Package*), que incluía diversos sensores: un barredor multi-espectral, dos sensores de micro-ondas y dos sensores fotográficos. Estos últimos eran la cámara multi-espectral (S 190A), con seis objetivos sensibles a distintas longitudes de onda entre 0,4 y 0,9 μm, y la cámara de observación terrestre (ETC, *Earth Terrain Camera*), dotada de una gran focal (457 mm), que se diseñó para obtener fotografías de alta resolución (15 m) a 435 km de altitud (NASA, 1977). A partir de estas fotografías se realizaron estudios temáticos muy variados: cobertura del suelo, cartografía litológica, vegetación y cultivos (Hart, 1975; Links, 1976; NASA, 1977).

A consecuencia del éxito de esta experiencia, se concibieron esperanzas de que las cámaras espaciales sirvieran como base para la restitución fotogramétrica —por procedimientos similares a los practicados con fotografía aérea—, remediando así la gran carencia mundial de cartografía básica. Hasta el momento se han diseñado tres cámaras de alta precisión con estos fines: la cámara métrica RMK 20/23, la cámara de gran formato (LFC) y la cámara multi-espectral MKF-6.

La cámara métrica RMK 20/23 se construyó por la casa Zeiss para proporcionar fotografías estereoscópicas de gran precisión y elevada cobertura, con un formato convencional (23 × 23 cm). Fue incluida en la primera misión *Spacelab* de la Agencia Espacial Europea (1983), a bordo del transbordador espacial estadounidense. Esta misión permitió adquirir unas 1.000 fotografías con película pancromática

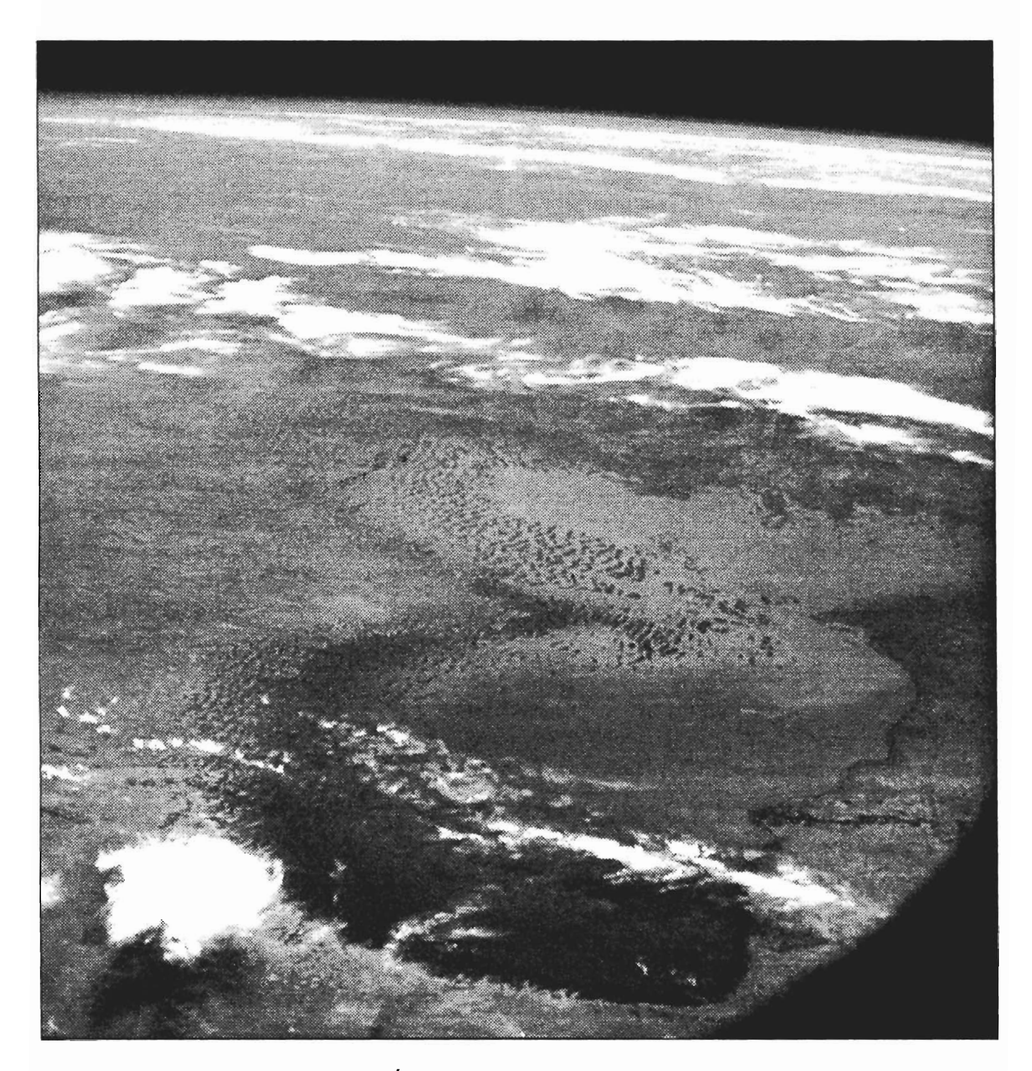


FIG. 3.9. *Imagen del Lago Chad, África, adquirida en octubre de 1968 por el Apollo 7. Cortesía del Earth Sciences and Image Analysis Laboratory, NASA Johnson Space Center.*

e infrarrojo color sobre varias regiones del mundo, cubriendo una zona aproximada de 11 millones de km^2 (Konecny, 1986). La longitud focal era de 305 mm, lo que proporcionó una escala aproximada de 1:820.000 a 250 km de altura, con una resolución estimada entre 20 y 30 m. La cobertura estereoscópica se cifró en 60 %, aunque en áreas montañosas se extendió hasta el 80 %. Las restituciones practicadas a partir de estas fotografías se obtuvo cartografía básica a escala 1:100.000 (Schroeder, 1986).

Un ejemplo de este tipo de fotogramas puede analizarse en la figura 3.10. Se trata de un par estereoscópico enmarcado entre los Picos de Urbión y la Sierra de Ayllón, en la región central española, cubriendo un área aproximada de 15.000 km^2. Aquellos lectores familiarizados con la fotografía aérea, posiblemente queden fasci-

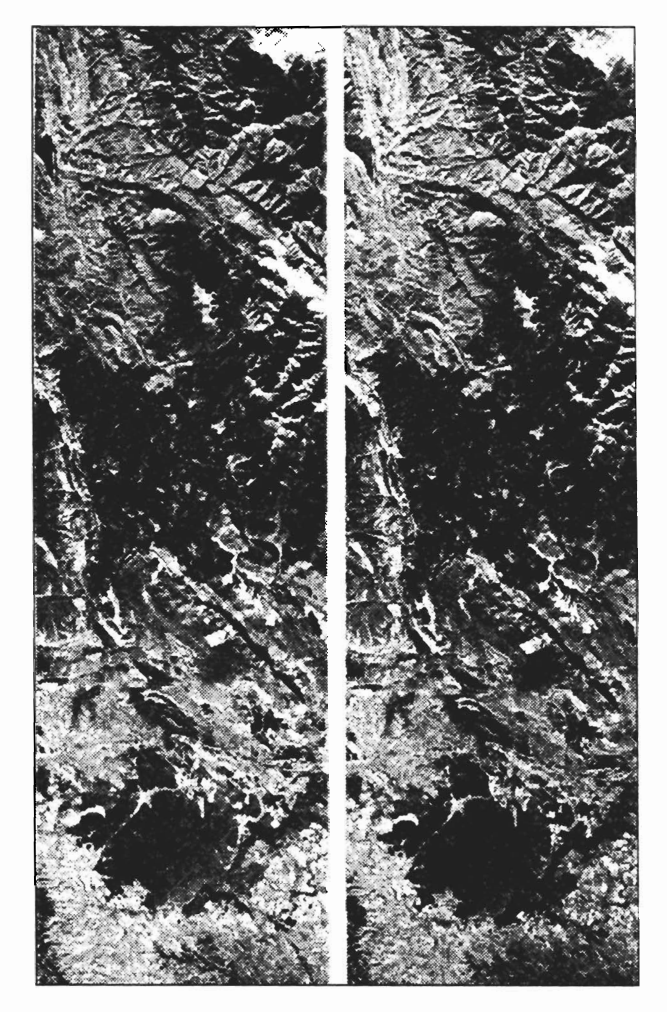


FIG. 3.10. *Par estereoscópico de la cámara métrica RMK 20/23 sobre los Picos de Urbión y pinares de Soria (Cortesía R. Núñez de las Cuevas).*

nados al percibir el relieve de una zona tan extensa, contemplada desde 250 km de altura. Junto a los rasgos morfológicos que ofrecen estas fotografías, resulta también de gran interés su visión panorámica, global, de las cubiertas vegetales, sin olvidar su aplicación cartográfica, principal objetivo de esta misión. El cambio de orientación en las misiones del *Space Shuttle*, tras el desastre del *Challenger* en 1986, interrumpió el empleo de esta cámara.

Similar suerte corrió la cámara de gran formato (*Large Format Camera*, LFC). Diseñada por ITEK con la misma finalidad que la cámara europea (cartografía básica), su principal novedad consistía en ampliar el área observada, gracias a disponer de un formato de 23 × 46 cm (frente al 23 × 23 convencional). Esta cámara se empleó por vez primera en la misión 41-G del *Space Shuttle* (1984), obteniéndose una variada colección de fotografías con un recubrimiento de hasta el 80 %, lo que

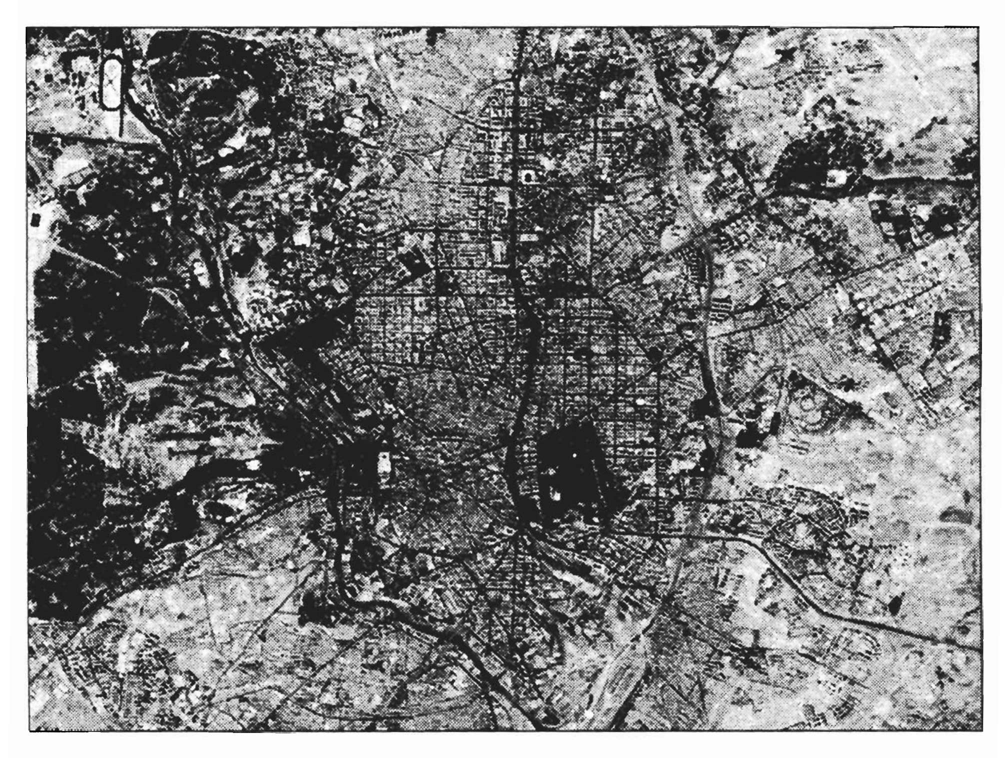


FIG. 3.11. *Fotografía de la cámara de gran formato (LFC) sobre la ciudad de Madrid y alrededores (Cortesía R. Núñez de las Cuevas y F. Doyle).*

facilitó precisiones en altura de 30 m, a una escala 1:50.000 (Togliatti, 1986). La misma cámara ha sido empleada en otras misiones del trasbordador espacial norteamericano, tanto con películas pancromáticas como color (Francis y Jones, 1984; Lulla, 1993).

Un buen ejemplo de la información adquirida por esta cámara aparece en la figura 3.11, que abarca un pequeño sector de una fotografía de la cámara LFC, en este caso centrada en la ciudad de Madrid. Se pone en evidencia la buena resolución espacial de la imagen, que permite extraer rasgos de gran interés sobre la imagen: morfología metropolitana, red viaria, expansión urbana, etc.

En las últimas misiones del trasbordador norteamericano, se han utilizado cámaras más convencionales, como la Hasselblad de 70 mm y Aerotechnika de 5 pulgadas. Recientemente se han comenzado experiencias con la cámara digital ESC *(Electronic Sill Camera)* que ofrece una resolución de 1024 × 1024 píxeles en blanco y negro, aunque se estudia su ampliación a la misma resolución en color y hasta 2048 × 2048 en blanco y negro (Lulla, 1993). Las fotografías tomadas por las diversas misiones del *Space Shuttle* pueden adquirirse en el *Global Land Information System* (GLIS), un servidor web del *U.S. Geological Survey* que permite acceder a múltiples datos gestionados por este centro, así como a imágenes Landsat, CORONA y fotografías aéreas. La mayor parte de las fotografías almacenadas en este centro son en color natural, aunque una pequeña parte son en blanco y negro y otras en

infrarrojo color. El archivo corresponde a las 55 misiones del trasbordador espacial que han tomado fotografías de la superficie terrestre. Más recientemente se están comenzando a utilizar las fotografías de las misiones combinadas del *Space Shuttle* y la nave soviética MIR, especialmente en análisis de cambios ambientales (Lulla y Dessinov, 2000), sin desdeñar las fotografías tomadas por la estación espacial.

Desde el punto de vista del análisis de cambios en el paisaje resulta de gran interés la decisión de la Casa Blanca en 1995 de permitir la comercialización de fotografías tomadas por satélites militares estadounidenses (McDonald, 1995). Se trata de fotografías adquiridas por los satélites CORONA, ARGON y LANYARD, comprendidas entre 1960 y 1972, a lo largo de más de 100 misiones. Estas fotografías tienen formatos muy variados, dependiendo de las misiones. La resolución espacial varía entre 150 y 2 m, aunque son más habituales las comprendidas entre 2 y 10 m. Las escalas nominales varían entre 1:275.000 y 1:4.250.000, y el área abarcada por las fotografías varía entre 18 × 234 km, y 480 × 480 km. Las fotografías pueden conseguirse a través del servidor de imágenes del servicio geológico de EE.UU. Esperemos que en un inmediato futuro sigan desclasificándose las fotografías de satélites militares, ya que proporcionan niveles de resolución todavía mucho mayores que la observación civil.

Los satélites rusos también han incluido diversos sensores fotográficos, algunos de alta precisión. Una de las más destacadas es la cámara multiespectral MKF-6, instalada a bordo de diversas misiones del satélite Soyuz. Dotada de seis objetivos, permitió obtener fotografías sobre seis bandas del espectro, del azul al infrarrojo cercano. También fueron muy empleadas las cámaras KFA-200, a bordo de los satélites RESURS-F, con una resolución espacial de 25-30 m y 3 bandas espectrales (verde, rojo e infrarrojo cercano), la pancromática KFA-1000, con resolución de 8-10 m, y la MKF-4, multiespectral con 12 a 14 m de resolución (Kramer, 2002). Estas fotografías facilitaron una información muy valiosa para el estudio de los recursos naturales, hídricos y minerales (Sagdejew, 1982; Strain y Engle, 1993). Gracias a un acuerdo con la empresa norteamericana *Aerial Images, Inc*, y a través del servidor de imágenes Terraserver (www.terraserver.com), podían conseguirse fotografías digitales del satélite ruso Cosmos. Este satélite está equipado con dos cámaras, la KVR-1000 que permite obtener hasta 2 m de resolución sobre un área de 160 km de lado, y la TK-350, con 10 m de resolución y 200 km de anchura (en este caso con capacidad estereoscópica). Un ejemplo de la calidad de estos datos puede observarse en la figura 3.12, que cubre el casco histórico de la ciudad de Alcalá de Henares. Los detalles que proporciona sobre la estructura y morfología urbana eran bastante equiparables a la fotografía aérea, si bien han quedado ahora superadas por las imágenes de los satélites comerciales de alta resolución.

3.2. Exploradores de barrido

Las características técnicas de los sensores fotográficos impiden que desde ellos se realice una cobertura sistemática de la superficie terrestre, pues están limitados por la cantidad de película que pueden cargar a bordo. Por esta razón se diseñaron otros sensores, denominados genéricamente óptico-electrónicos, ya que com-



FIG. 3.12. *Imagen de la cámara KVR-1000 sobre la ciudad de Alcalá de Henares adquirida en 1987 (Alcalá87; origen: www.terraserver.com).*

binan una óptica más o menos similar a la fotografía, con un sistema de detección electrónica, que evita la dependencia de una superficie sólida de grabación.

Entre estos sensores, los más habituales en teledetección espacial son los exploradores o rastreadores de barrido *(scanners)*. Un espejo móvil, que oscila perpendicularmente a la dirección de la trayectoria, les permite explorar una franja de terreno a ambos lados de la traza del satélite. La radiancia recibida por este componente óptico se dirige a una serie de detectores, que la amplifican y convierten a una señal eléctrica. Ésta, a su vez, se transforma a un valor numérico, que puede almacenarse a bordo o transmitirse a la red de antenas receptoras (fig. 3.13). La información recibida por estas antenas se graba en soporte magnético para su posterior proceso y distribución a los usuarios.

En suma, el sensor convierte una señal analógica, la radiancia procedente del suelo, en un valor digital, siguiendo unos parámetros fijos diseñados por el fabricante. En otras palabras, la conversión analógico-digital que realizan es constante en cualquier lugar, lo que permite realizar el proceso contrario y obtener la radiancia original a partir de los valores digitales, para lo que basta conocer los coeficientes de calibrado del sensor. Esto supone, en pocas palabras, que estos sensores no sólo facilitan una representación gráfica, sino también una medición física de la superficie que observan, a intervalos regulares en el terreno dependiendo de la resolución

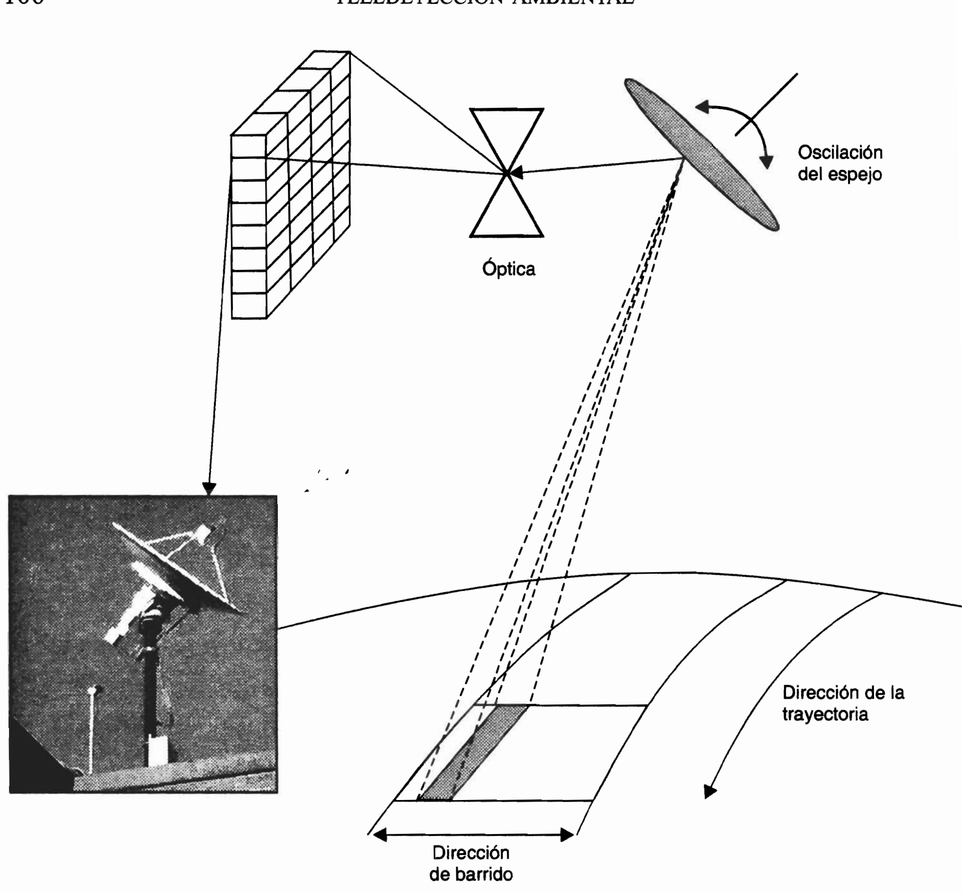


FIG. 3.13. *Diagrama de un explorador de barrido.*

espacial del sensor. Aunque el formato de una imagen resultante es similar al de las fotografías digitales, o las fotografías escaneadas, el sentido físico de los valores no lo es, puesto que tiene un sentido físico propio que en los dos casos anteriores sólo es relativo.

El número y características de los detectores que incorpora un equipo de barrido es muy importante para explicar las condiciones de la imagen resultante. La señal enviada por el equipo óptico a estos detectores se muestrea a intervalos regulares, de tal forma que únicamente se graba un valor numérico cada cierta distancia. Ese intervalo marca el tamaño de la unidad mínima de información adquirida por el sensor, que se denomina píxel. En la mayor parte de los equipos de exploración por barrido, la señal recibida se descompone a bordo en varias longitudes de onda, cada una de las cuales se envía a un tipo especial de detectores, sensibles a ese tipo de energía. En ese caso, se habla de exploradores de barrido multiespectral (o incluso hiperespectral), pues detectan la misma superficie de terreno en distintas bandas del espectro. El número y anchura de esas bandas —lo que hemos denominado resolución espectral— está en función del diseño del propio sensor: del número de detectores con que cuente, de su óptica, capacidad de almacenamiento y transmisión de datos, etc.

Las ventajas más claras de los equipos de barrido multiespectral, en relación con los sensores fotográficos, pueden sintetizarse en los siguientes puntos:

1. Permiten ampliar la banda del espectro detectada a longitudes de onda mayores del visible. Las emulsiones fotográficas están limitadas al rango 0,4 a 0,9 µm (visible e infrarrojo reflejado), mientras los equipos de barrido pueden abarcar de 0,4 a 12,6 µm, incluyendo el SWIR, IRM e IRT.
2. Capacidad de convertir los datos registrados en radiancias.
3. Posibilidad de realizar coberturas sistemáticas, y de grandes espacios, gracias a su capacidad de transmitir datos en tiempo real.
4. Grabación digital de la información, que asegura su fiabilidad y permite su tratamiento asistido por ordenador.

Su principal problema hasta hace unos años era su menor resolución espacial respecto a los sistemas fotográficos, pero este inconveniente se está mitigando notablemente, gracias a los avances en la electrónica microscópica.

Gracias a las características arriba comentadas, los equipos de barrido multi-espectral se han incorporado sistemáticamente a las principales misiones de teledetección desde el espacio. Los más utilizados han sido los incluidos en los programas Landsat (MSS, *Multispectral Scanner*, TM, *Thematic Mapper*, y ETM, *Enhanced Thematic Mapper*), TIROS-NOAA (AVHRR, *Advanced Very High Resolution Radiometer*), Nimbus (CZCS, *Coastal Zone Color Scanner*), Skylab (S192), DMSP (*Operational Linescan System*, OLS), HCMM (HCMR, *Heat Capacity Mapping Radiometer*), ERS (ATSR ATSR (*Along Track Scanning Radiometer*), y el soviético RESURS (*MSU-E* y *MSU-SK*), entre otros.

3.3. Exploradores de empuje

En los años ochenta se puso a punto una nueva tecnología de exploración, denominada «por empuje» *(pushbroom)*. En estos equipos se elimina el espejo oscilante, gracias a disponer de una cadena de detectores que cubre todo el campo de visión del sensor. Estos detectores se van excitando con el movimiento orbital del satélite, de ahí el nombre de explorador de empuje, puesto que se explora, en cada momento, una línea completa, desplazándose ésta simultáneamente con la plataforma (fig. 3.14). Los detectores sólidos que forman un explorador por empuje se denominan dispositivos de acoplamiento por carga (*Charge Couple Devices, CCD)*.

Esta tecnología permite aumentar la resolución espacial del sistema respecto a los barredores convencionales, gracias a eliminar la parte móvil, mientras se reducen algunos problemas geométricos que se producen en los barredores, caso de que se perdiera la sincronía entre el movimiento del espejo y el de la plataforma. Además no se requiere que los detectores sean interrogados una vez por píxel, como ocurre en los exploradores de barrido, sino sólo una vez por línea, lo que agiliza la detección y emisión de datos. Por otra parte tienen las mismas ventajas que los exploradores de barrido en cuanto a que la información es digital y corresponde a distintas bandas del espectro, más allá del VIS.

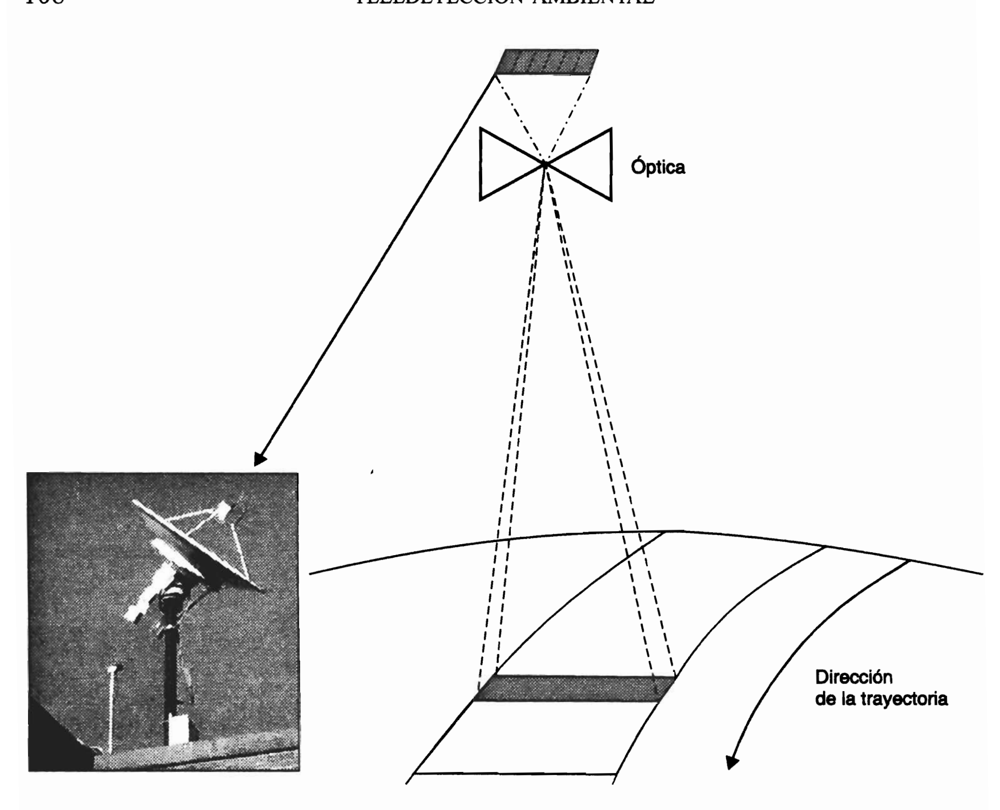


FIG. 3.14. *Diagrama de un explorador por empuje.*

Como contrapartida, uno de los problemas importantes que atañe a estos nuevos equipos es la difícil calibración de su cadena de detectores. Al aumentar notablemente su número, se precisa de complejos mecanismos de ajuste para que éstos traduzcan, de la misma forma en todos los casos, la señal recibida. De lo contrario faltaría homogeneidad entre las columnas de la imagen, afectando a su calidad final. Otro problema aún no bien resuelto en estos sistemas es ampliar la información espectral que proporcionan, incluyendo al infrarrojo térmico. Hasta el momento presente, se han diseñado equipos mono y multi-espectrales, limitados al VIS, IRC y SWIR. El trabajo en el térmico resulta mucho más complejo por el tipo de detectores que precisa, muy sensibles al calor y de difícil calibración.

Los exploradores de empuje se han ido incorporando en las dos últimas décadas a la mayor parte de los proyectos de teledetección espacial, a partir de la puesta en órbita del satélite SPOT (sensores HRV y HRVIR). Otros satélites con este tipo de sensores son el indio IRS (sensor PAN, LISS y WIFS), los norteamericanos EO-1 (ALI, Hyperion), IKONOS y Quickbird, y los japoneses MOS (MESSR), JERS-OPS y ALOS, entre otros muchos.

3.4. CÁMARAS DE VÍDEO

Durante las primeras misiones de los satélites de teledetección también se emplearon bastante las cámaras de vídeo, que podían trabajar en forma pancromática o multi-banda. En esta tecnología la imagen es enfocada sobre un foto-conductor, construyéndose una réplica electrónica de la imagen original, que se mantiene en esa superficie hasta que el haz de electrones la barre de nuevo, restaurando así su equilibrio (fig. 3.15).

Este modelo de funcionamiento se modificó en el caso del RBV *(Return Beam Vidicon)*, a bordo de los primeros satélites Landsat. En estos sistemas, la señal de la cámara se derivaba de la porción no utilizada del haz de electrones, que retornaba a lo largo de la misma trayectoria que el rayo incidente, y era amplificado electrónicamente. Ese mecanismo permitió mejorar la resolución espacial de los equipos de barrido y del vídeo convencional, por lo que fue incluido en algunas misiones espaciales: Apollo, Mariner, TIROS, Nimbus, Bhaskara-1 y 2, así como en los tres primeros satélites de la serie Landsat, aunque sólo funcionó adecuadamente en el tercero.

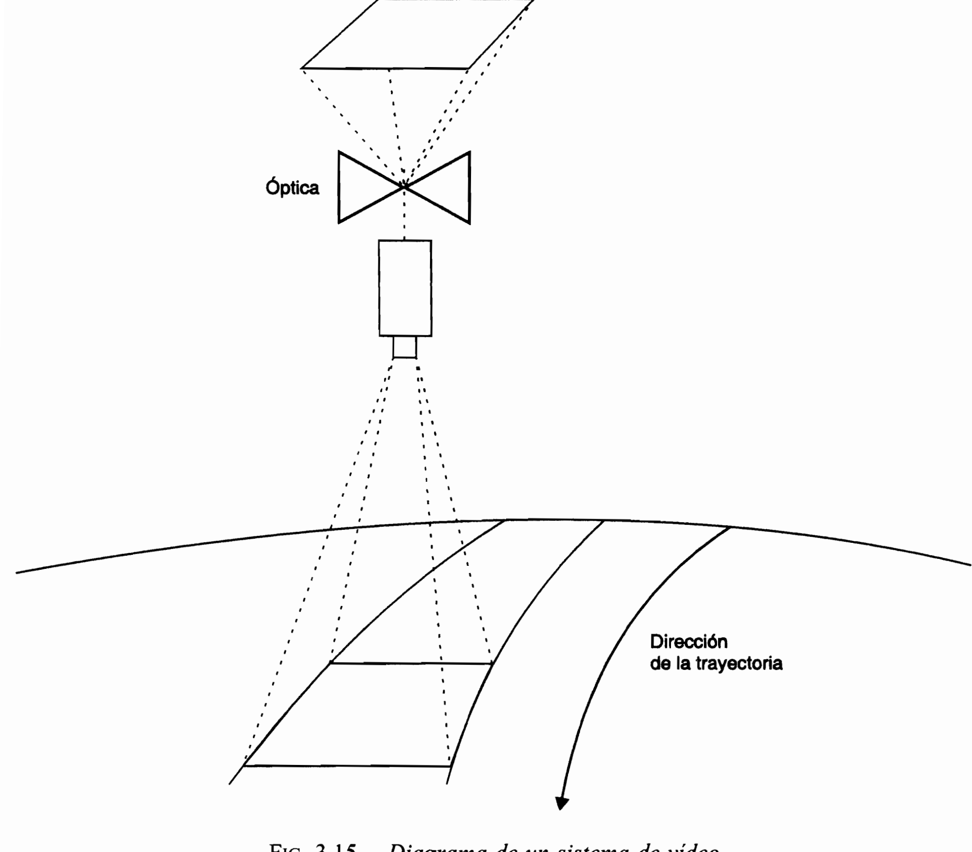


FIG. 3.15. *Diagrama de un sistema de vídeo.*

Más reciente resulta el empleo de las cámaras de vídeo digital como fuente de imágenes en proyectos de gran escala. La videografía se define así como una nueva técnica de teledetección, que permite obtener información calibrada con gran nivel de detalle y bajo coste (especialmente si se utilizan cámaras convencionales). Su principal interés sobre la fotografía aérea es su inmediata disponibilidad y facilidad de manejo. Su principal inconveniente es la baja resolución (está limitado a un campo de visión no superior a 500 píxeles con las tecnologías convencionales), que obliga a tomar los datos desde baja altura (Linden, 2000).

3.5. Radiómetros de micro-ondas

Se trata de sensores que operan en el rango del espectro correspondiente a longitudes de onda milimétricas, normalmente entre 6,8 y 90 GHz. Por ello, no están afectados por la situación atmosférica ni por las condiciones de iluminación.

El radiómetro está compuesto por un elemento direccional, un receptor, que permite la detección y amplificación de las micro-ondas, y un detector. Su gran desventaja estriba en la pobre resolución espacial que proporciona, ya que, al tratarse de un sensor de abertura circular, la resolución es inversamente proporcional al diámetro de abertura y directamente a la longitud de onda. En consecuencia, para poseer una adecuada resolución sería preciso contar con una antena de enormes proporciones, lo cual no es factible en misiones espaciales.

Pese a este problema, los radiómetros de micro-ondas se han utilizado con gran aprovechamiento para diversos estudios medioambientales (Choudhury *et al.*, 1994). Uno de los campos en donde ha mostrado mayor interés es en la cartografía de hielo y nieve, gracias a ser muy sensibles a las bajas temperaturas.[1] Esto ha permitido obtener información del estado de la capa de hielo, así como diferenciar tipos de nieve en función de su compacidad y temperatura. A este respecto, los sensores SSMR *(Scanning Multichannel Microwave Radiometer)*, a bordo del Nimbus-5 y 6, el *Special Sensor Microwave Imager* (SSM/I) del DMSP, y el *Advanced Microwave Scanning Radiometer* (AMSR) sobre el EOS Aqua se han empleado con gran eficacia para cartografiar la nieve y capas de hielo, y detectar movimientos de icebergs (Kelly y Hall, 2008). Un mapa térmico de ambos casquetes polares fue obtenido a partir de estas imágenes en 1977, revelando información de gran interés para el estudio de estas áreas, difícilmente accesibles por otros medios (Hall y Martinec, 1985). Los datos de los radiómetros de micro-ondas se han mostrado también muy convenientes para estimar las condiciones de humedad en el suelo y el estrés hídrico en la vegetación (Choudhury y Nicholson, 1992). La apertura a usos civiles de los datos adquiridos por el satélite militar DMSP *(Defense Meteorological Satellite Program)* facilita la continuidad de estas observaciones, ya que cuenta con un equipo muy similar al del Nimbus, denominado SSM/I *(Special Sensor Microwave Imager)*, que proporciona información en varias frecuencias, registrando tanto polariza-

1. Recuérdese que, de acuerdo a las leyes de Planck y Wien {2.4 y 2.6}, cuanto mayor sea la temperatura de una superficie, emitirá más intensamente a longitudes de onda más cortas. Por tanto, sólo las cubiertas más frías son perceptibles a estas longitudes de onda.

ción horizontal como vertical. También la misión TRMM *(Tropical Rainfall Measuring Misión)* cuenta con un equipo de estas características, el TRMM *Microwave Imager* (TMI), diseñado para estimar la lluvia sobre el océano, así como las del EOS-Aqua y el japonés ALOS.

4. Sensores activos

4.1. RADAR

Característica común de los sistemas activos es su capacidad de emitir un haz energético que, posteriormente, recogen tras su reflexión sobre la superficie que se pretende observar. Entre ellos, el sistema más conocido es el radar, radiómetro activo de micro-ondas, que trabaja en una banda comprendida entre 0,1 cm y 1 m. Cada píxel en una imagen radar representa el coeficiente de retro-dispersión de esa área sobre el terreno, siendo el valor almacenado tanto mayor cuanto más intensa sea la señal de retorno. Gracias a su flexibilidad —puede trabajar en cualquier condición atmosférica (fig. 3.16)—, el radar ha pasado a un primer plano en los programas de observación de la Tierra, obteniendo múltiples aplicaciones en la última década (Henderson y Lewis, 1998).

Podemos distinguir tres tipos de radar: aquellos que se orientan a adquirir imágenes, los que miden distancias (altímetros), y los que miden campos de viento (dispersómetros). Los más utilizados son los primeros, que permiten medir la intensidad de la señal de retorno, de forma similar a como hacen los equipos ópticos, aunque aquí se realiza lateralmente, lo que supone una serie de errores geométricos que ahora comentaremos.

Un radar se puede configurar de formas muy variadas, obteniendo señales de retorno potencialmente también muy diversas. Puede diseñarse con distintas bandas de observación, a distintas alturas, con distintos ángulos de observación, con distintos tamaños de antena y distintas polarizaciones. La ecuación fundamental del radar puede expresarse como sigue:

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 r^4} \qquad \{3.2\}$$

donde P_r, indica la potencia retro-dispersada; P_t, la potencia emitida por el radar, G es un factor de ganancia de la antena; σ es la sección eficaz de retro-dispersión, y r la distancia entre el sensor y la cubierta. De esta fórmula se entiende que, a estas longitudes de onda, la señal de retorno depende notablemente de la potencia emitida y la altura de observación, por lo que para montar radares orbitales, se requiere una enorme potencia o que la antena tenga una ganancia efectiva muy alta, lo cual depende del tamaño de la antena y de la longitud de onda. De esta forma, la ecuación anterior también puede expresarse como:

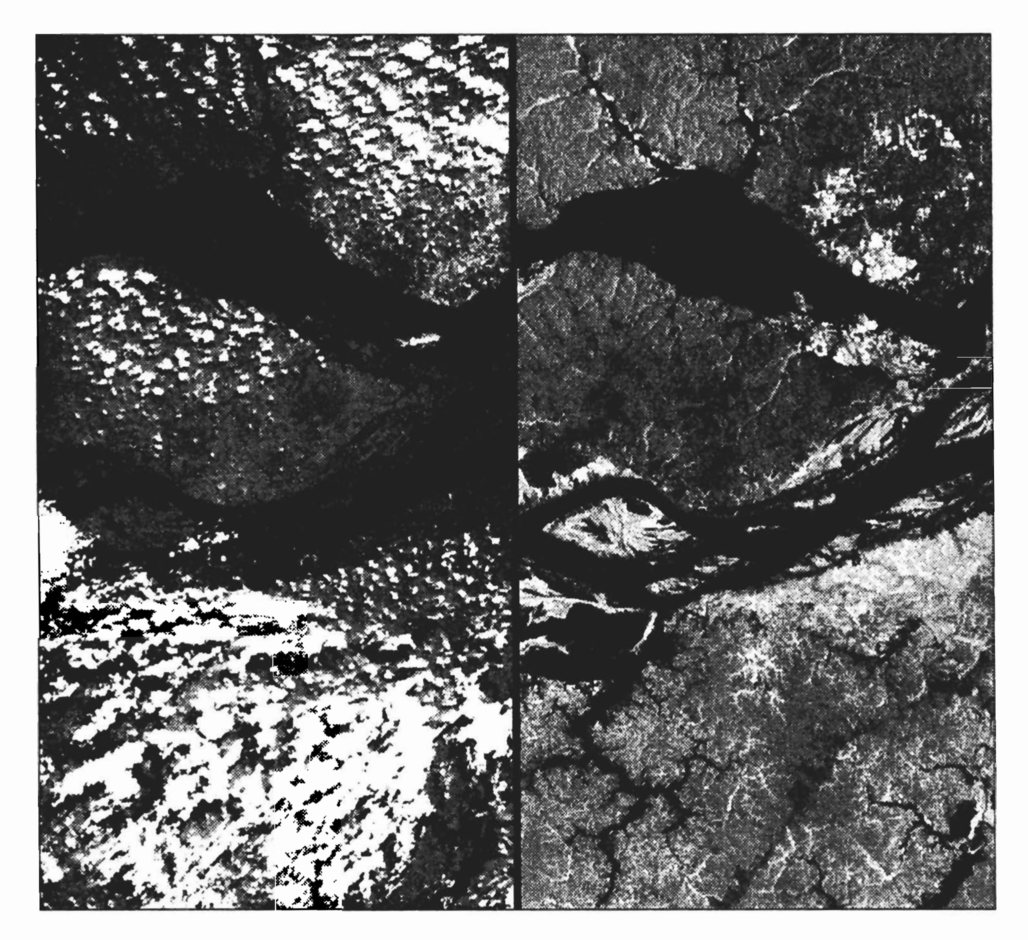


FIG. 3.16. *Imágenes adquiridas por el JERS-1 en 1993 sobre los alrededores de la ciudad de Manaos (Brasil). En la izquierda aparece uno de los canales ópticos del sensor OPS, mientras a la derecha figura una imagen del radar. Resulta evidente la capacidad de este último sensor para observar zonas cubiertas por nubes. Cortesía NASDA.*

$$P_r = \frac{P_t A^2 \sigma}{4\pi\lambda^2 r^4} \qquad \{3.3\}$$

donde A es el área de la antena receptora. Esto quiere decir que a mayor altura, el tamaño de la antena debería ser mayor para obtener una buena señal en el suelo. En concreto, la resolución espacial del radar puede calcularse como:

$$R_s = \frac{\lambda r}{\phi} \qquad \{3.4\}$$

siendo ϕ el diámetro de abertura de la antena. Esto anularía el empleo del radar en plataformas espaciales, pues para lograr una resolución adecuada sería preciso contar

con antenas de enormes proporciones. Tal inconveniente, no obstante, puede obviarse con el empleo del radar de abertura sintética (SAR, *Synthetic Aperture Radar).* Su principio de operación se basa en el efecto Doppler, que afecta a la observación realizada cuando existe un movimiento relativo entre objeto y sensor. En el caso del SAR, se registran los pulsos de un mismo punto de la superficie terrestre en dos momentos distintos de la trayectoria, con lo que la resolución es equivalente a la que se obtendría con una antena de similar longitud a la distancia existente entre ambos puntos (Elachi, 1987). Por ejemplo, en el radar del Radarsat, la apertura real de la antena es de 10 m, y la apertura sintética que se consigue es de 48 km, lo que le permite a 851 km de distancia obtener una resolución en el terreno de 5 m en modo fino.

Hasta aquí la resolución en acimut (paralela a la trayectoria). Como el radar realiza una observación lateral, la resolución en profundidad (*range*, perpendicular a la trayectoria) no es constante, ya que la distancia efectiva al suelo cambia entre los dos bordes de la imagen (Lewis *et al.*, 1998), con lo cual los píxeles más cercanos a la trayectoria ocupan un área efectiva más pequeña que los más alejados. La corrección de este efecto (denominado *slant-range*), se realiza sabiendo el ángulo de incidencia efectivo para cada píxel (fig. 3.17).

La resolución en profundidad también depende de la duración de los pulsos emitidos. Para que el sistema pueda discriminar entre dos objetos, su distancia en el terreno ha de ser superior a la mitad de la longitud del pulso (la mitad porque el pulso tiene que enviarse y regresar). Además hay que considerar que la distancia aparente al radar entre los objetos depende del ángulo de incidencia (θ). Para aumentar la longitud del pulso es preciso disminuir la frecuencia, lo que implica que haya mayor probabilidad de ruido. Esta paradoja se soluciona modulando la frecuencia de

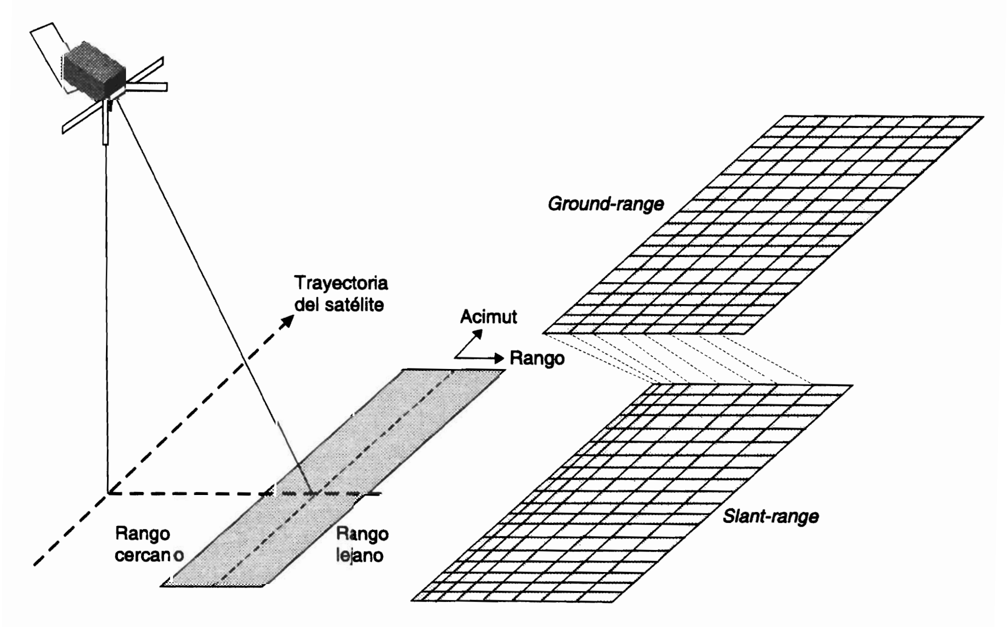


FIG. 3.17. *Geometría de observación lateral en una imagen radar. La resolución en rango cambia entre los dos extremos de la imagen (adaptado de ESA: http://earth.esa.int/applications/).*

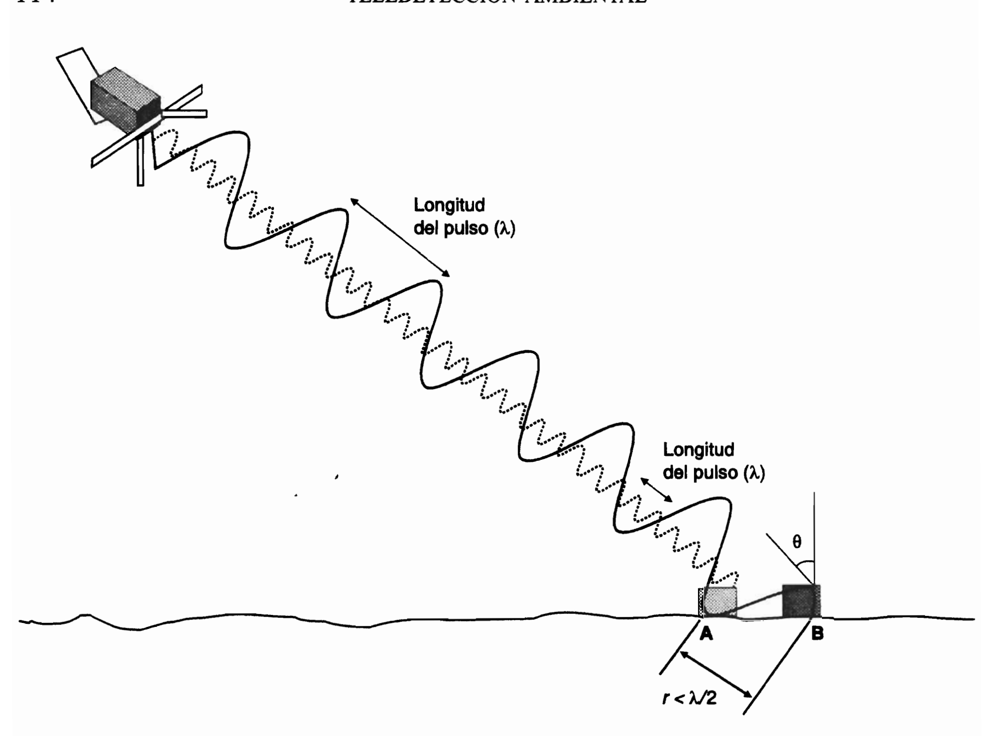


FIG. 3.18. *Resolución en profundidad de un sistema radar: cuando se trabaja a longitudes de onda más largas, los objetos cercanos tienden a mezclarse en la señal retrodispersada. Cortesía Iksu A. Kyun.*

los pulsos emitidos y recibidos. En resumen, la resolución en profundidad viene marcada por (fig. 3.18):

$$r_p = \frac{c}{2B \, sen \, \theta} \qquad \{3.5\}$$

donde c refiere a la velocidad de la luz, B al ancho de banda y θ al ángulo de incidencia de la onda.

En la geometría de adquisición de imágenes radar tiene una gran influencia el relieve, que modifica el ángulo local de incidencia, además de transformar la superficie real en superficie proyectada sobre la imagen (fig. 3.19). Si la pendiente es menor que el ángulo de incidencia, la imagen ofrece las distancias reales como acortadas. De ahí que las vertientes orientadas hacia la antena aparezcan como inclinadas hacia la dirección de la antena (acortadas, *foreshortening*), mientras las vertientes opuestas se alargan. El efecto más severo se produce cuando el haz radar llega antes a la cúspide de un fuerte relieve que a su base. Entonces la geometría se desfigura notablemente, observándose un solapamiento inverso (*layover:* fig. 3.19*b*), a consecuencia de que sus ecos lleguen a la antena en forma inversa a su posición respecto a la trayectoria. Estos factores pueden corregirse mediante análisis digital de

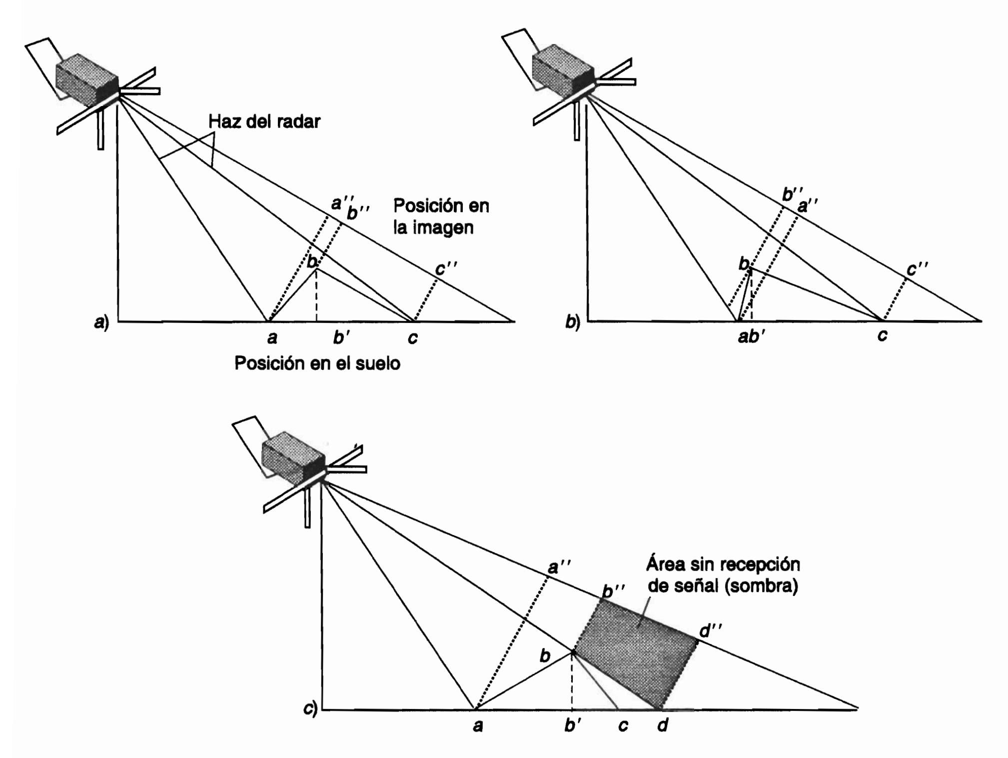


FIG. 3.19. *Efectos del relieve sobre la imagen radar:* a) *las distancias se acortan cuando el relieve es muy pronunciado;* b) *si el relieve es extremo los objetos pueden aparecer en orden inverso al que realmente ocupan;* c) *con ángulos de incidencia bajos, parte del área queda a la sombra del radar. Cortesía Iksu A. Kyun.*

las imágenes si está disponible un modelo digital del terreno de suficiente fiabilidad. Más complicado resulta corregir el efecto del relieve cuando deja en sombra las vertientes opuestas a la dirección de observación (fig. 3.19*c*). Este fenómeno, que depende de la altitud del terreno y del ángulo de incidencia, implica perder la información de esas laderas, aunque puede recomponerse si el satélite está diseñado para pasar por el mismo lugar con dos ángulos distintos (pasada ascendente y descendente), como ocurre con el europeo ERS.

Un ejemplo de los severos efectos geométricos que se producen en una imagen radar sobre una zona montañosa aparece en la figura 3.20, donde se han incluido dos imágenes adquiridas por el SAR del ERS-1 con seis días de diferencia, adquiridas en la pasada descendente y ascendente del satélite. El área corresponde al inicio de la Sierra de Gredos, entre las localidades del Tiemblo y Mijares. Al tratarse de un sector con fuertes contrastes topográficos, se observa una notable discrepancia geométrica entre las dos imágenes. Puede observarse cómo el relieve se «inclina» hacia la dirección de la trayectoria en los dos casos, y cómo quedan en sombra algunas vertientes que miran en sentido contrario a la orbita.

En cuanto a los problemas radiométricos, el más importante es el conocido como «*speckle*» (moteado), que aparece como consecuencia de las interferencias

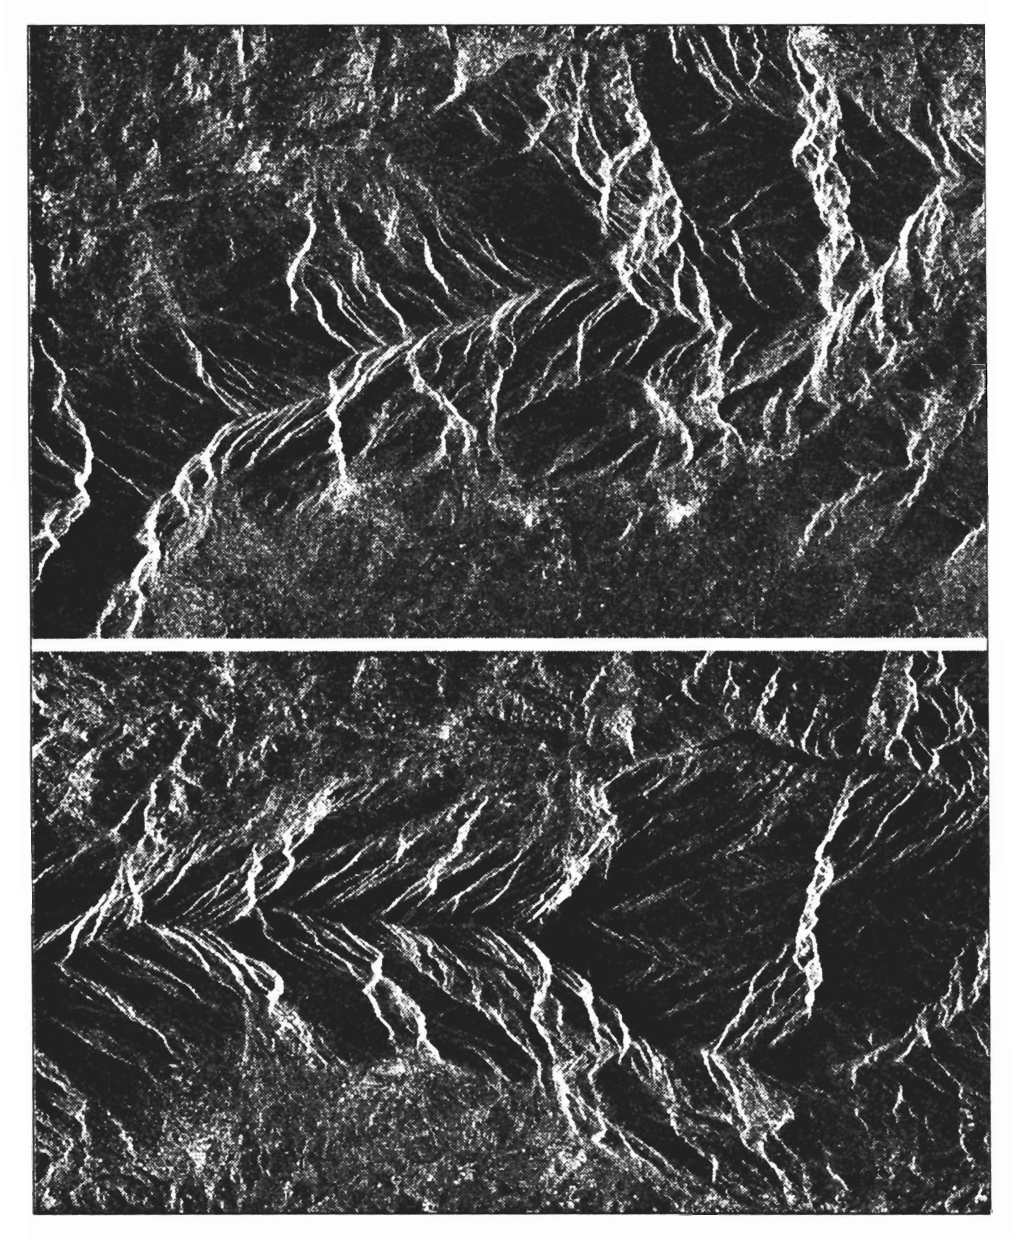


FIG. 3.20. *Imágenes SAR del ERS-1 sobre la Sierra de Gredos. En la parte superior, pasada descendente (23 de abril de 1993); en la inferior, pasada ascendente (29 de abril de 1993).*

que se producen entre las diversas vistas que se requieren para generar una imagen con la técnica de abertura sintética. El efecto es un moteado brillante, más o menos aleatorio sobre la imagen, que añade ruido y degrada las relaciones físicas, complicando la clasificación de la imagen. Puede solventarse con algunos filtros digitales, que luego comentaremos en el capítulo 6.

Pese a los problemas geométricos y radiométricos, el radar de abertura sintética ha sido uno de los sensores de mayor desarrollo en las últimas décadas, a consecuencia de su gran versatilidad de observación, ya que es independiente de las condiciones atmosféricas y de la iluminación solar. Sus posibilidades para el análisis de la vegetación son amplias, complementando la observación de los sensores ópticos. Entre las principales aplicaciones cabe citar la cartografía de la cobertura del suelo (basada en la rugosidad), la detección de alteraciones producidas por incendios o talas, la estimación de algunos atributos forestales (alturas promedio, área basal, biomasa, volumen maderero) y el seguimiento de la regeneración vegetal tras un evento catastrófico (Dobson, 2000).

Los progresos en la tecnología radar se dirigen a obtener equipos más versátiles, que mejoren la resolución espacial y/o ofrezcan observación multiangular, multifrecuencia y multipolarización. Los equipos radar instalados sobre plataformas espaciales han trabajado principalmente en una sola frecuencia, un solo ángulo y un solo nivel de polarización, pero los más recientes están ampliando mucho esas capacidades. El primer radar espacial se instaló a bordo del SEASAT, activo por un corto período de tiempo en 1978 para investigación oceanográfica. Tras él, se han desarrollado varias misiones europeas (ERS, Envisat), rusas (Almaz), japonesas (JERS, ALOS: fig. 3.21) y canadienses (RADARSAT). Además, se han montado radares en el *Space Shutte,* tanto para adquirir imágenes (misiones SIR), como para medir alturas (SRTM).

La figura 3* recoge una magnífica imagen de la Isla de Tenerife adquirida por el SIR-C el 11 de octubre de 1994. La imagen ofrece una composición en color de la banda L (polarización HH) en rojo, la banda L (polarización HV) en verde, y la banda C (HV) en azul. Se observan magníficamente los principales rasgos geomorfógicos de la isla. Junto al Teide, se observan distintos flujos de lava en tonos de gris.

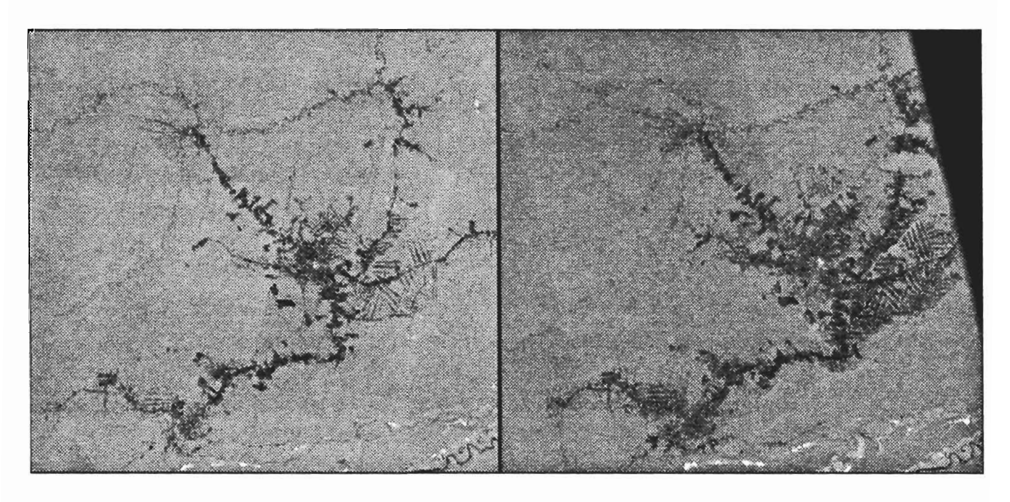


FIG. 3.21. *Imágenes radar de un sector en el oeste de Rondonia (Brasil) que muestra el avance de la deforestación en 11 años: izquierda, imagen JERS de 1995; derecha, imagen ALOS PALSAR de 2006 (http://www.eorc.jaxa.jp/ALOS/img_up/pal_forest_amz_rondonia.htm).*

Además del radar de imágenes, algunos de estos satélites incorporan otros equipos activos de micro-ondas, como el altímetro, que mide con mucha precisión la distancia entre el satélite y la superficie marina (Robin, 1998, p. 37), y le permite en consecuencia seguir las variaciones del nivel del mar o de lagos interiores. Esta variable resulta de gran interés actualmente en el marco del seguimiento de los impactos del calentamiento climático (Shepherd *et al.*, 2003), puesto que permite obtener tendencias temporales sobre grandes superficies. Asimismo, el altímetro se ha utilizado muy eficazmente para predecir y analizar el fenómeno del Niño, que modifica la altura del océano Pacífico entre las costas americanas y las del sudeste asiático. En este sentido, la misión Topex-Poseidon y Jason-1, han proporcionado información muy valiosa para entender mejor los patrones de cambio asociados a este fenómeno (Cherniawsky *et al.*, 2004).

También resulta muy importante la aportación del dispersómetro de vientos, que mide los campos de vientos (dirección y velocidad) sobre el océano. Aunque el SAR de los satélites ERS tenía esta capacidad, el interés de esta variable se ha podido explorar con mayor hondura gracias al lanzamiento del Quikscat, que facilita información prácticamente diaria sobre campos de vientos marinos en todo el planeta (Munoz *et al.*, 2004).

Finalmente, conviene considerar algunas de las nuevas potencialidades abiertas por las técnicas de interferometría, que permiten estimar pequeñas variaciones en el terreno a partir de estudiar la diferencia de fase en el pulso radar para dos adquisiciones muy cercanas en el tiempo (Madsen y Zebker, 1998; Quegan, 1995). El principio es sencillo, si dos flujos de micro-ondas con la misma fase se envían al terreno casi simultáneamente, las diferencias de fase entre ellos serán debidas a las variaciones del terreno que encuentran o a movimientos de la superficie. Esas diferencias están en el mismo orden de la longitud de onda que estemos utilizando (pocos centímetros para los radares que se utilizan habitualmente). Esas interferencias pueden reconstruirse siempre que se pueda medir con mucha precisión la línea de base (distancia entre las dos antenas) y la altura orbital. La interferometría puede hacerse desde un satélite con dos antenas, desde dos satélites que funcionen en tándem, o desde el mismo satélite en pasadas sucesivas, siempre y cuando no haya cambios perceptibles entre las dos pasadas. Esto es lo que se llama coherencia del terreno, medida habitualmente como la desviación típica de las diferencias de fase. Alta coherencia indica que las imágenes tienen buena relación señal-ruido, que la retrodispersión es estable o que los movimientos tienen una organización espacial. Normalmente es baja para el agua, moderada en la vegetación y alta en los desiertos y ciudades. En zonas semiáridas se han podido obtener pares interferométricos con imágenes adquiridas hasta con varios meses de desfase (Massonet *et al.*, 1993), mientras en áreas de mayor densidad vegetal, incluso cambios en la intensidad del viento pueden hacer perder la coherencia entre imágenes. La interferometría permite detectar el movimiento siempre que haya alta coherencia y poco relieve, y se ha utilizado para el seguimiento de glaciares, terremotos (Massonet *et al.*, 1995) y fenómenos de subsidencia.

A partir del lanzamiento del ERS-2 se llevaron a cabo las primeras experiencias interferométricas, poniendo en tándem los dos satélites ERS disponibles para adquirir imágenes en un intervalo muy corto de tiempo. Ahí se reveló el interés de

esta técnica, tanto para generar modelos de elevación, como para analizar movimientos del terreno. Sin embargo, la disponibilidad de pares interferométricos era escasa, por lo que su impacto operacional fue limitado. Los buenos resultados de estas experiencias facilitaron el diseño de un proyecto específico para recoger información interferométrica. Así nació la *Shuttle Radar Topography Mission* (SRTM), embarcada en el vuelo STS-99 del *Space Shuttle* en febrero de 2000. Esta misión incorporó dos radares, separados unos 60 m gracias a un mástil instalado en el trasbordador espacial, lo que le permitió una adquisición de datos muy precisa (Rabus *et al.*, 2003). A partir del procesamiento de esta información, se ha generado un modelo digital del terreno de casi todo el planeta con una resolución de 30 m, que está disponible públicamente (fig. 4*).

4.2. LÍDAR

El lídar *(Light Detection and Ranging)*, es un sensor activo que emite pulsos de luz polarizada entre el ultravioleta y el infrarrojo cercano (Dubayah y Drake, 2000; Kobayashi, 1987). En la mayor parte de los sistemas, se emplea como transmisor un láser que transmite un pulso colimado (altamente direccional), coherente (fase homogénea) y polarizada (vectores alineados). Esta señal interacciona con las partículas atmosféricas o el suelo, causando su dispersión en función del tipo de elemento encontrado. La energía de retorno se recoge por un telescopio, que a su vez la transmite a través de un filtro óptico a un foto-detector. Esta señal eléctrica es grabada y posteriormente almacenada en un ordenador. En función del tiempo y la intensidad de la señal de retorno, puede deducirse una información muy significativa sobre el tipo de cubierta presente en la zona de estudio.

Existen distintos sistemas lídar, de acuerdo a los principales tipos de dispersión: de Mie, Rayleigh y Raman, de resonancia, de absorción diferencial, y de fluorescencia inducida (Kobayashi, 1987). Cada uno de estos tipos se orienta a aplicaciones específicas. Hasta hace pocos años, los más utilizados se dirigían a explorar las condiciones atmosféricas: detección de aerosoles y partículas contaminantes del aire, medición de la humedad, presión y temperatura del aire, y estimación de la velocidad del viento. Las experiencias desarrolladas hasta el momento han ofrecido resultados muy interesantes (Huffaker *et al.*, 1984).

En lo que se refiere a la teledetección de cubiertas terrestres, los lídar más utilizados son el de fluorescencia inducida (Chapelle *et al.*, 1984) y el medidor de distancias (altímetro lídar) (Fujii y Fukuchi, 2005). El primero permite detectar manchas de aceite, algas y contaminantes del agua, condiciones de humedad en la vegetación y contenido de pigmentos. Para los estudios topográficos y cálculos de biomasa se ha utilizado con bastante intensidad en los últimos años el altímetro lídar, diseñado para medir con mucha precisión distancias desde un punto emisor. Estos equipos emiten un haz láser en el R o IRC mediante un barrido de un área a ambos lados de la trayectoria del avión (fig. 3.22*a*), con lo que pueden obtenerse representaciones bidimensionales de los datos. Puesto que las observaciones son puntuales, si quiere obtenerse una imagen continua de alturas, habitualmente la altura de cada píxel se obtiene extrayendo valores promedio, máximos o mínimos de los

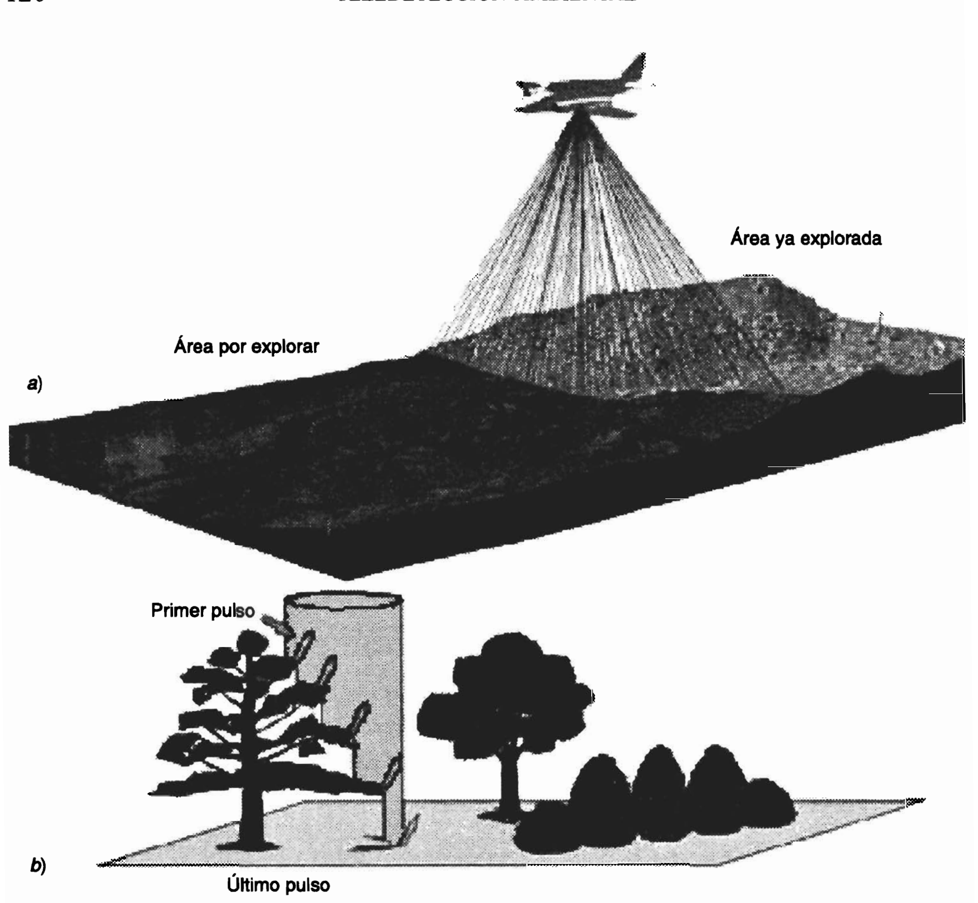


FIG. 3.22. *Principio de funcionamiento del explorador lídar de imagen* a), *y reconstrucción de las señales de retorno* b) *(adaptado de www.toposys.com).*

pulsos de retorno que se hayan encontrado en la superficie abarcada por cada píxel (la resolución dependerá de la densidad de puntos por superficie), aunque también pueden hacerse análisis punto a punto.

Suelen establecerse dos tipos de altímetro lídar, en función del tamaño en el suelo del pulso emitido. Se habla así de sistemas de huella pequeña (los más habituales), con un tamaño en el suelo de 20 a 40 cm, y los sistemas de huella grande, con un área observada de varias decenas de metros. Habitualmente los primeros detectan el primer y último retorno, esto es la distancia con el primer y último objeto con el que se encuentran. Por su parte, los sistemas de huella grande suelen registrar la onda completa de retornos, almacenando las distancias a todos los objetos que se encuentran, como un histograma de distancias en función del tamaño global de la huella.

A partir de diversos criterios puede obtenerse la línea de base que marcaría la altura de la base del suelo para cada sector observado. Conociendo con mucha precisión la posición del sensor en altura, puede calcularse la altura de esa línea base, que expresaría el modelo digital de elevación. La diferencia de alturas con esa línea

base nos indicaría la altura de los objetos observados. Para el caso de la vegetación, si los pulsos son muy densos algunos se reflejarán en la copa de los árboles, otros en ramas intermedias, otros en el matorral y otros en el suelo (fig. 3.22*b*). Analizando las diferencias entre las distancias registradas podrá reconstruirse la estructura vertical de la masa forestal que se esté estudiando (Dubayah y Drake, 2000; Lefsky *et al.*, 1999). Puede, por ejemplo, determinarse no sólo la altura de los árboles, sino también la diferencia con la base de la copa o la presencia del matorral bajo arbolado (Riaño *et al.*, 2004*a*). Además, la distribución de los pulsos que se reflejan a distintas alturas resulta un buen indicador del índice de área foliar o de la fracción de cabida cubierta (Riaño *et al.*, 2004*b*). La precisión de estas estimaciones depende bastante de la rugosidad del terreno, de la altura de observación, de la altura de la vegetación y del espaciamiento vertical entre los distintos estratos vegetales (Riaño *et al.*, 2007*a*).

Para las zonas urbanas, basta habitualmente el primer pulso reflejado para conocer la altura de los edificios (Zhou *et al.*, 2004), lográndose una imagen muy detallada de la organización urbana (fig. 2*). Su alta precisión en la medición de distancias le permite mejorar mucho los métodos tradicionales para generar modelos digitales de elevación, especialmente en zonas de relieve suave, como son las llanuras de inundación, por lo que se ha utilizado bastante en análisis de riesgos (Webster *et al.*, 2006).

En definitiva, el lídar supone un sensor de gran potencialidad para estudios topográficos y de biomasa vegetal, al facilitar información tridimensional muy precisa, que puede complementar notoriamente la recogida en otras bandas del espectro. Su principal problema radica en la dependencia, al igual que las otras longitudes de onda ópticas, de las condiciones atmosféricas, así como a requerir un consumo de energía bastante elevado para su funcionamiento en una plataforma espacial. Por estas razones, hasta el momento la mayor parte de los sensores lídar son aeroportados y de pequeña huella (Baltsavias, 1999). Durante varios años se trabajó en una misión orbital orientada al análisis de la vegetación. Este proyecto, denominado *Vegetation Canopy Lidar* (VCL), pretendía instalar en órbita un lídar de gran huella (25 m), trabajando en el IRC y registrando un área de 8 km de lado, digitalizando la onda de retornos completa. Aunque se aprobó inicialmente para lanzarse en 2000, finalmente se ha cancelado y es bastante incierto su inmediato futuro.

Sí que se ha puesto en órbita, sin embargo, otra misión lídar, aunque orientada principalmente hacia estudios de hielo y nieve. Se denomina, por esa razón, ICESat, y fue lanzada con éxito en 2003. Este satélite incorpora un equipo lídar de gran huella (70 m) que se denomina GLAS *(Geoscience Laser Altimeter System)*. Trabaja en dos longitudes de onda (IRC y V) y proporciona onda de retornos completa, con una separación entre huellas de 170 m en la dirección del barrido. Cuenta con un sistema de posicionamiento estelar muy preciso, que le permite medir alturas con bastante precisión. Se dirige principalmente al seguimiento de las capas de hielo y nieve (Thomas *et al.*, 2004: fig. 3.23), pero también cuenta con interesantes aplicaciones en el análisis de nubes/aerosoles y en vegetación, si bien aquí las estimaciones son poco precisas cuando el terreno es rugoso (Harding y Carabajal, 2005).

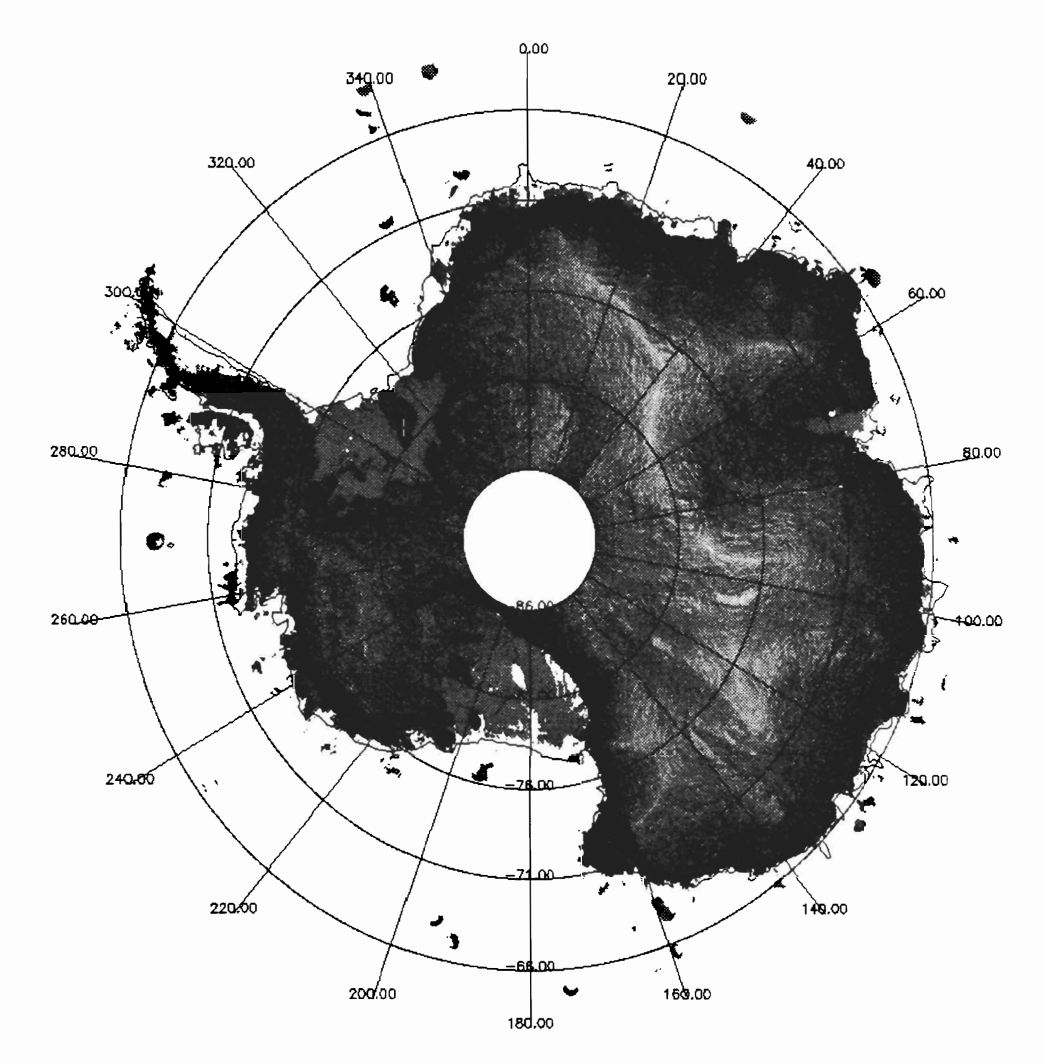


FIG. 3.23. *Modelo de elevación de la Antártida generado a partir de datos ICESAT (http://icesat.gsfc.nasa.gov/).*

5. Plataformas de teledetección espacial

La última parte de este capítulo se dedica a revisar las características de los proyectos más interesantes de teledetección desde el espacio. Bajo la óptica de quien pretende obtener información temática de una imagen, este comentario puede ser útil en la medida en que ofrezca un panorama de la información actualmente disponible. Con la rapidez con la que se diseñan y ponen en órbita las misiones de teledetección, necesariamente este texto debe irse actualizando mediante la información disponible en las agencias espaciales y empresas dedicadas a este sector.

Antes de iniciar esta sección, conviene hacer algunos comentarios someros sobre las características orbitales de un satélite. Los tres elementos más importantes de

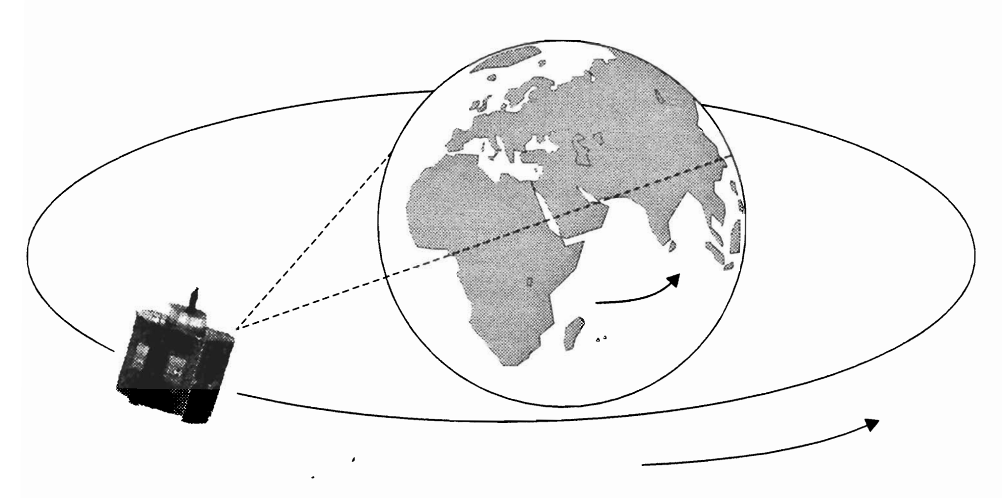


FIG. 3.24. *Esquema de una órbita geosíncrona.*

una órbita espacial son la altitud, la inclinación y el período orbital. La altitud puede ser constante, en cuyo caso se trataría de una órbita circular, o variar (órbitas elípticas), distinguiéndose en este caso entre el punto más lejano (apogeo) y el más cercano (perigeo). La inclinación se mide respecto al plano del Ecuador, y puede tratarse de órbitas ecuatoriales o polares, dependiendo del ángulo de cruce. El período indica la duración de una órbita completa, y depende de la velocidad orbital y de la altura.

Los satélites más comunes en teledetección se ajustan a dos órbitas, denominadas geosíncronas y heliosíncronas. La primera, que también se denomina geoestacionaria, es una órbita ecuatorial a 36.000 km de distancia. Su período orbital es el mismo que el de la Tierra, por lo que el satélite aparece siempre en la misma posición relativa (estacionario) respecto a la Tierra. Esto le permite observar siempre la misma zona (figura 3.24), por lo que es ideal para los satélites dedicados a la observación meteorológica (Meteosat, GOMS, Insat o GOES), ya que pueden tomar datos del mismo punto con bastante frecuencia. Puesto que orbitan con la Tierra, no pueden observar todo el planeta, sino el sector longitudinal en el que están posicionados: el Meteosat se sitúa sobre el meridiano 0° (para adquirir imágenes de Europa), mientras el GOES lo hace en los meridianos 70° y 140° W, enfocados hacia la costa Este y Oeste de EE.UU, respectivamente. Esta también es la órbita más utilizada por los satélites de comunicaciones.

En cuanto a la órbita heliosíncrona, cuenta con una inclinación próxima a los 90° (casi Polar), lo que permite observar en cada momento una zona distinta del planeta, hasta completar la observación, ya que la órbita es perpendicular al movimiento terrestre. Las alturas orbitales varían entre 600 y 900 km, y suele ajustarse el período orbital para que pasen por el Ecuador a la misma hora local, lo que les permite tomar imágenes en similares condiciones de iluminación si se comparan las mismas épocas del año (fig. 3.25). Esta órbita es la más habitual en los satélites de recursos naturales de media y alta resolución (Landsat, SPOT, IRS, IKONOS, Terra, Aqua, etc.), si bien también existen algunos ejemplos de órbitas ecuatoriales (incli-

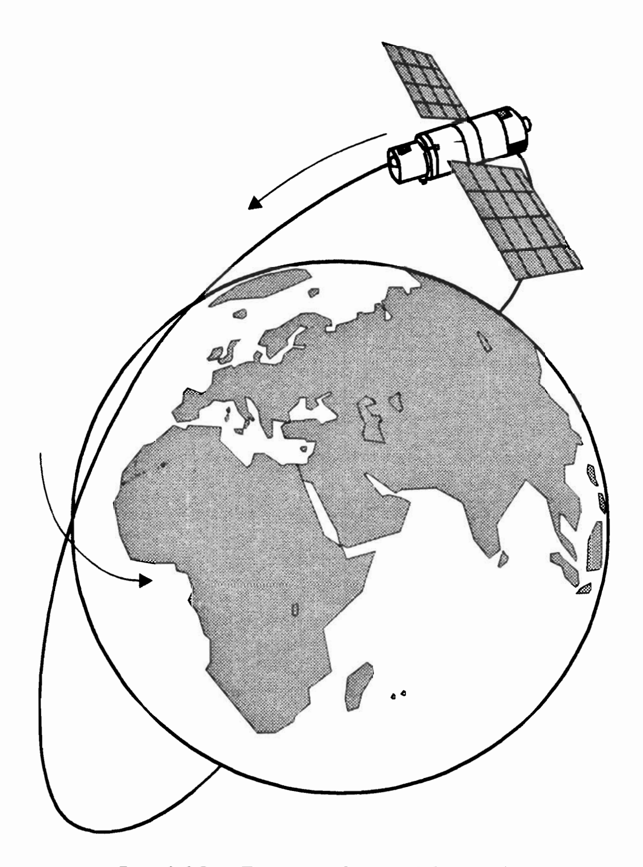


FIG. 3.25. *Esquema de una órbita polar.*

nación 5-10º), optimizadas para observar con más detalle las áreas cercanas tropicales. Este es el caso del satélite TRMM, por ejemplo.

La elección de la órbita que ocupa una plataforma viene determinada por las características de la misión del satélite: si se pretende tomar datos de una gran superficie en una sola imagen a fin de observar fenómenos globales y muy dinámicos (como la nubosidad), suele trabajarse con satélites geoestacionarios —o, en todo caso, con polares que cuenten con un amplio campo de visión—; por el contrario, si se pretende un mayor detalle en la observación, se utilizan plataformas de órbitas más bajas.

A continuación vamos a revisar algunas de las misiones más destacadas en teledetección espacial.

5.1. EL PROGRAMA LANDSAT

Gracias a los brillantes resultados que proporcionaron las primeras fotografías espaciales, la agencia espacial norteamericana diseñó a fines de la década del 60 el primer proyecto dedicado exclusivamente a la observación de los recursos terrestres.

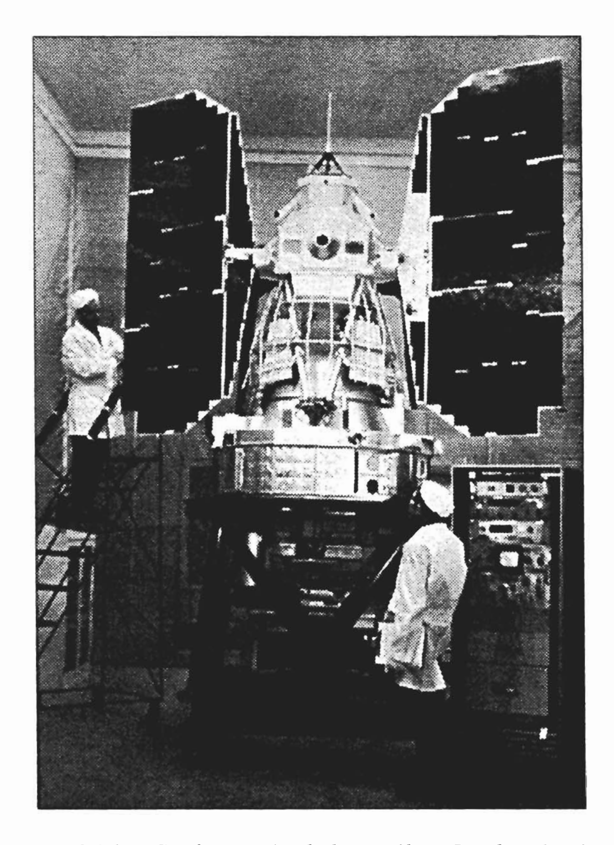


FIG. 3.26. *Configuración de los satélites Landsat-1 a 3.*

Fruto de estos trabajos fue la puesta en órbita del primer satélite de la serie ERTS *(Earth Resource Technollogy Satellite)* el 23 de julio de 1972. Esta familia de satélites, denominada Landsat a partir del segundo lanzamiento, en 1975, ha constituido, sin duda, el proyecto más fructífero de teledetección espacial desarrollado hasta el momento. La buena resolución de sus sensores, el carácter global y periódico de la observación que realizan y su buena comercialización, explican su profuso empleo por expertos de muy variados campos en todo el mundo (Goward *et al.*, 2006). Actualmente el archivo histórico Landsat proporciona una información de extraordinaria calidad para analizar los cambios producidos en las tres últimas décadas en la mayor parte de la superficie terrestre. Las imágenes son más abundantes en aquellos lugares cubiertos por antenas receptoras (Brasil, Argentina, Canadá, China, Italia, Suecia, Indonesia, Tailandia, Japón, India, Sudáfrica y Australia: http://landsat.usgs.gov/about_ground_stations.php, último acceso marzo 2008).

5.1.1. *Características orbitales*

Los primeros tres satélites Landsat tenían un aspecto similar a una mariposa por la disposición de los paneles solares (fig. 3.26). Sus dimensiones eran de 3 m de altura por 1,5 m de diámetro, que se tornaban en 4 m cuando se extendían dichos



FIG. 3.27. *Configuración de los Landsat-4 y 5.*

paneles. El peso total del sistema se aproximaba a los 960 kg. Su órbita era heliosíncrona, polar, ligeramente inclinada (99,1 grados). Con una altura orbital media de 917 km, circundaba la Tierra cada 103 minutos, con lo que realizaba 14 órbitas diarias para volver sobre la misma porción de la superficie terrestre a los 18 días, y a la misma hora local (entre las 9.15 y las 10.45 según latitudes). Con el fin de reducir al máximo las alteraciones en las condiciones de observación se dotó a los satélites de un sistema de estabilización según tres ejes, orientados hacia la superficie terrestre y la vertical del punto nadir. Las correcciones en la órbita, por tanto, se hacían desde las estaciones terrestres, lo que confería una gran estabilidad en la toma de datos.

Los dos siguientes, el Landsat-4 y 5, modificaron su fisonomía (fig. 3.27) y sus características orbitales. La altura de vuelo se reduce de 917 a 705 km, aunque se mejora el ciclo de recubrimiento, de 18 a 16 días en nuestras latitudes, gracias a un menor período orbital (98,9 minutos). El momento de adquisición, sin embargo, se mantiene en torno a las 9.45, hora solar en nuestras latitudes.

Los Landsat-6 y 7 volvieron a cambiar la forma del satélite (fig. 3.28), aunque se mantuvieron las características orbitales de sus predecesores. El Landsat-6 se perdió poco después del lanzamiento, por lo que sólo nos referiremos al último, lanzado en 1999. Se sitúa a una altura de 705 km, en órbita cuasi polar y heliosíncrona con una inclinación de 98,2° y un período de revisita de 16 días.

5.1.2. *Instrumentos de observación*

MSS

Los tres primeros Landsat incorporaban un equipo de barrido multiespectral denominado MSS *(Multispectral Scanner)* y un conjunto de tres cámaras de vídeo (RBV, *Return Beam Vidicon*). Los Landsat-4 y 5 eliminaron las cámaras RBV y las

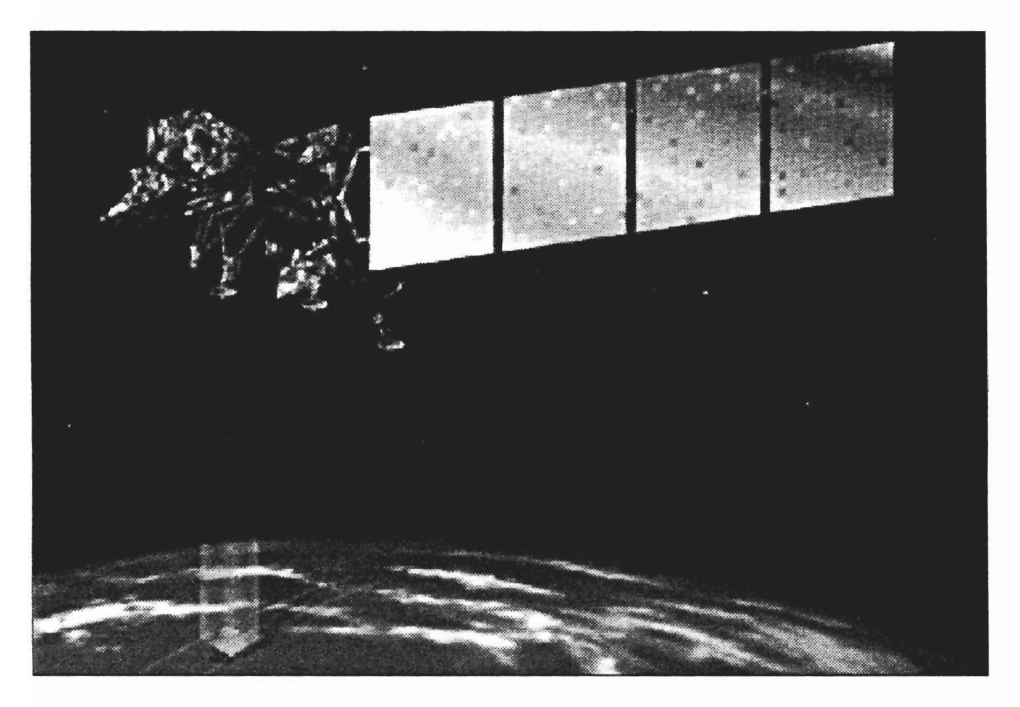


FIG. 3.28. *Aspecto del Landsat-7.*

sustituyen por un nuevo explorador de barrido, denominado TM *(Thematic Mapper)* que proporcionaba mayor resolución espacial y espectral que el previo MSS. Para asegurar la continuidad en la serie de datos, también se mantuvo el MSS en los dos Landsat-4 y 5, con similares características a los anteriores satélites.

El sensor MSS era un equipo de barrido óptico-electrónico con un campo total de visión de 11,56°, lo que, a la altura orbital del satélite, le permitía explorar una franja de terreno de 185 km, divididos a ambos lados de la vertical de la traza.

En el diseño del sensor MSS se tuvieron en cuenta las medidas espectrales de laboratorio, de tal forma que las 4 bandas finalmente incluidas pretendían realzar la aplicación de este sensor a la detección de masas vegetales, recursos hídricos y mineros (tabla 3.1).[2] Las bandas visibles (4 y 5), tienen mejores disposiciones para la detección de aspectos antrópicos, como áreas urbanas o vías de comunicación, a la vez que proporcionan una interesante información sobre la calidad del agua. Las dos bandas en el infrarrojo cercano (6 y 7) pretenden registrar parámetros vitales en la actividad de las plantas, además de ser especialmente sensibles a la humedad.

Con objeto de acoplar la secuencia de barrido a la velocidad del satélite, el sensor MSS registraba seis líneas simultáneamente con cada oscilación del espejo. La radiancia recibida por el sistema focal se transmitía a un sistema óptico que la descomponía en cuatro bandas y la enviaba a distintos detectores. Por tanto, el MSS

2. A lo largo del capítulo se incluirán tablas con las características técnicas de los principales sensores comentados. Aquellos que no se recogen en el texto, con objeto de simplificar la exposición, aparecen citados en la web del libro.

TABLA 3.1. *Sensores a bordo del programa Landsat*

MSS[1]		*RBV*		*TM*[2]		*ETM+*[3]	
4	0,5-0,6 μm	1[4]	0,475-0,575 μm	1	0,45-0,52 μm	1	045-0,52 μm
5	0,6-0,7 μm	2[4]	0,580-0,680 μm	2	0,52-0,60 μm	2	0,52-0,60 μm
6	0,7-0,8 μm	3[4]	0,690-0,830 μm	3	0,63-0,69 μm	3	0,63-0,69 μm
7	0,8-1,1 μm	1[5]	0,505-0,750 μm	4	0,76-,90 μm	4	0,76-0,90 μm
8[5]	10,4-12,6 μm			5	1,55-1,75 μm	5	1,55-1,75 μm
				6	10,40-12,50 μm	6	10,40-12,50 μm
				7	2,08-2,35 μm	7	2,08-2,35 μm
						8	0,52-0,90 μm
Resolución espacial							
4-7[1]	79 m	1-3[4]	80 m	1-5, 7	30 m	1-5, 7	30 m
						6	120 m[2]-60 m[3]
8[5]	240 m	1[5]	40 m	6	120 m	8	15 m

1. Sólo en los Landsat-1 a 5.
2. Sólo en el Landsat-4 y 5.
3. Sólo en el Landsat-7.
4. Sólo en los Landsat-1 y 2.
5. Sólo en el Landsat-3.

disponía de 24 detectores (6 líneas × 4 bandas), compuestos por foto-diodos de silicio (banda 7), y por tubos foto-multiplicadores (bandas 4 a 6). En el caso del Landsat-3, se añadió una banda térmica (banda 8), registrada por detectores de mercurio-cadmio-telurio. La cobertura espectral ofrecida por el MSS aparece en la tabla 3.1.

Las señales analógicas que producen los detectores eran amplificadas, convertidas a formato digital y enviadas directamente a las estaciones receptoras, desde donde se iniciaba la distribución de las imágenes. Cuando el satélite no se encontraba en el área de influencia de alguna antena terrestre, los primeros Landsat incorporaban un sistema de grabación a bordo denominada WBVTR *(Wide Band Video Tape Recorders)*, que permitió adquirir imágenes de la mayor parte de la superficie emergida.

Una escena adquirida por el sensor MSS comprendía 2.340 líneas de barrido y 3.240 columnas por línea. Cada píxel correspondía a una superficie real de 79 m de lado (0,62 ha), si bien en la transformación digital se le asignaba un formato nominal de 57 × 79 m, lo que explicaba la disimetría final entre el número de líneas y de columnas en la imagen. La radiancia recibida para esa parcela del terreno se transformaba a un valor entero para su almacenamiento en cintas magnéticas (CCT). En los primeros MSS, ese valor de codificación estaba comprendido entre 0 y 127 para las bandas 4 a 6 (7 bits), y entre 0 y 63 para la banda 7 (6 bits). Los posteriores MSS codificaban las cuatro bandas entre 0 y 255 (8 bits), la medida estándar en un equipo de tratamiento digital.

RBV

Los dos primeros satélites Landsat incorporaron un sistema de tres cámaras de vídeo, denominadas RBV *(Return Beam Vidicon)*, cada una de las cuales registraba información en una banda espectral comprendida entre el verde y el IRC (tabla 3.1).

Su resolución espacial se cifraba en 80 m, cubriendo la misma porción superficial del sensor MSS.

Este sistema no funcionó adecuadamente en los dos primeros Landsat, por lo que fue sustituido en el tercero por otro. En este caso, el planteamiento se dirigió más a mejorar la resolución espacial que la espectral, por lo que se montaron dos cámaras pancromáticas de mayor resolución operando simultáneamente con el MSS. Estas cámaras cubrían un abanico espectral de 0,505 a 0,705 μm, proporcionando —en cuatro adquisiciones— la misma cobertura del MSS, pero con una resolución aproximada de 40 m. El registro entre ambas permitió utilizar el RBV como auxiliar del MSS, especialmente para mejorar la calidad visual de sus imágenes. Para ello, se emplearon diversas técnicas de fusión, que luego tendremos ocasión de comentar. En el campo de las aplicaciones temáticas, el RBV se ha utilizado en estudios morfológicos (Tricart, 1981) y en cartografía de la cubierta del suelo (King, 1981), si bien la escasa pervivencia de este sensor ha reducido sensiblemente su rango de aplicaciones.

TM y ETM+

Como antes se indicó, el lanzamiento de los Landsat-4 y 5 supuso un notable impulso del programa Landsat. Su principal aportación consistió en incorporar un nuevo sensor, denominado *Thematic Mapper* (TM), directamente diseñado —como su nombre indica— para la cartografía temática.

Al igual que su predecesor, el MSS, el *Thematic Mapper* es un equipo de barrido multiespectral, que emplea una técnica muy similar a la descrita previamente. Sin embargo, las novedades que incorpora permitieron considerarlo como parte de una nueva generación de sensores. Frente al MSS, el TM aumentaba el número de detectores, de 24 a 100, a la vez que reducía el campo de visión instantáneo, aumentaba los niveles de codificación y realizaba el barrido en las dos direcciones. Todo ello le permitió mejorar la resolución espacial, espectral y radiométrica frente al MSS: de 79 a 30 m, de 4 a 7 bandas, y de 6 a 8 bits. En el TM, cada oscilación del espejo suponía 16 líneas de barrido, frente a 6 en el MSS. De esta forma se precisaban 16 detectores por banda, salvo la banda térmica que registraba una menor resolución (120 m) y sólo requería cuatro detectores. Este aumento en el número de detectores complicó el proceso de calibración, a la par que aumentaba el volumen de datos a procesar frente al MSS, si bien pronto se superaron las limitaciones con la mejora en las capacidades de proceso alcanzadas en los años ochenta. Los detectores están formados por tubos de silicio, para las bandas 1 a 4, indio-antimonio para las bandas 5 y 7, y mercurio-cadmio-telurio para la banda 6.

En el último Landsat lanzado hasta el momento (el 7, en 1999) se incorporó un nuevo sensor, el ETM+, que mejora las características del TM, añadiéndole una banda pancromática de 15 m de resolución (fig. 3.29), y aumentando la resolución de la banda térmica a 60 m (con dos niveles de ganancia, por lo que se distribuyen dos bandas térmicas distintas). La inclusión del canal pancromático está siendo de gran utilidad para obtener productos cartográficos de mayor calidad, aplicando técnicas de fusión de datos (7.1.7).

El incremento de la resolución espacial y espectral que ofrecen tanto el TM como el ETM+, ha permitido mejorar notablemente la precisión obtenida en múlti-

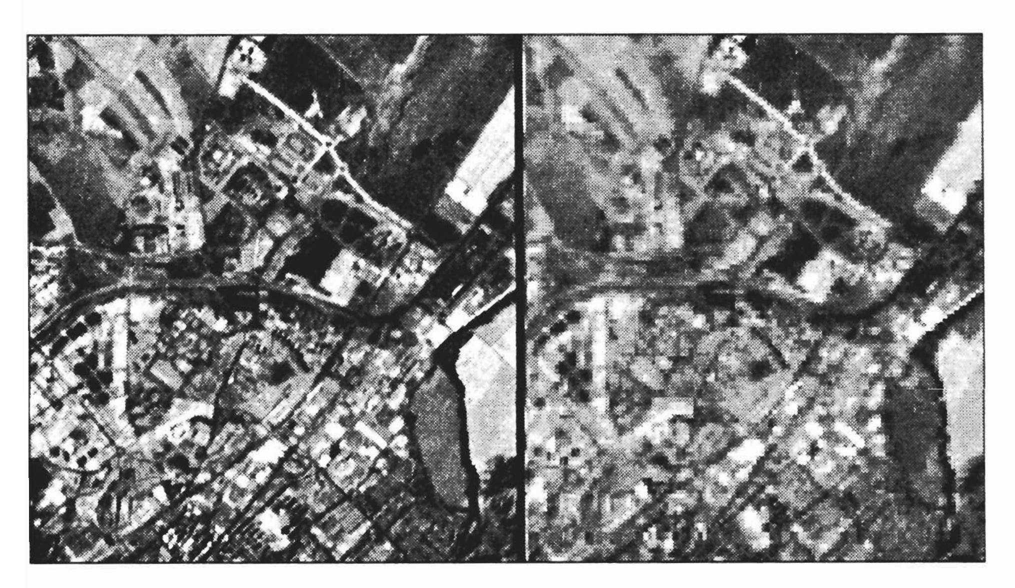


FIG. 3.29. *Imagen pancromática del ETM+ de la ciudad de Alcalá de Henares (Alcalá99). La mejora en la resolución espacial (15 m) puede observarse por comparación con la imagen de la derecha, que incluye la banda roja de la misma escena (30 m).*

ples ámbitos de la cartografía temática, a la vez que facilita ampliar el rango de aplicaciones operativas de los satélites Landsat. En este sentido, el diseño de estos sensores pretendió paliar las deficiencias observadas en las imágenes MSS, incorporando información de cuatro bandas del espectro no contempladas en el MSS (azul, dos en el SWIR y una en el IRT), mientras se sustituían las bandas 6 y 7 de ese sensor —ambas en el IRC— por una sola, sin perder información sustancial (tabla 3.1)

Con esa nueva configuración, el TM y ETM han aportado una sensible mejora en las aplicaciones terrestres y marinas del sensor MSS: detección de turbidez y contaminantes en el agua (banda azul), exploración minera (SWIR), contenidos de humedad en las plantas y suelo (SWIR), detección de focos de calor (SWIR e IRT), además de mantener las aplicaciones antes señaladas para el sensor MSS.

A la vez, el lanzamiento del Landsat-7 llevó consigo una severa reducción de los costes de las imágenes, lo que extendió notablemente la demanda de estos datos. Desafortunadamente, en mayo de 2003 se produjo un fallo en el mecanismo de barrido (*Scan Line Corrector,* SLC), que supone perder parte de los datos originales, ya que están descompensados los mecanismos de movimiento perpendicular y horizontal. En definitiva, esto supone que en los extremos de la imagen queden zonas sin cubrir, lo que deteriora notablemente el uso de los datos en esas zonas. No obstante, el sensor sigue operando con buena calidad radiométrica, por lo que siguen registrándose imágenes operativamente.

5.1.3. *El futuro del programa Landsat*

La amplitud temática y geográfica de los usuarios del programa Landsat explica el gran interés que la comunidad científica internacional ha brindado a esta fami-

lia de satélites. Como antes comentamos, la Administración Reagan impulsó la transferencia del programa Landsat al sector privado en 1984 (O.T.A., 1984). Pocos meses más tarde, en 1985, la compañía EOSAT recibía los derechos para vender productos Landsat por un período de diez años, con el compromiso de participar en el desarrollo de futuros sensores. Por su parte, el gobierno mantenía la responsabilidad en el control físico de la plataforma (a través de la agencia NOAA, con amplia experiencia en la gestión de los satélites meteorológicos), mientras que se comprometía a colaborar en el desarrollo de los Landsat-6 y 7. Nuevos recortes presupuestarios pusieron en entredicho este compromiso, hasta el punto de llegar a una situación límite, a inicios de 1989, en el que se temió por la continuidad de los propios Landsat-4 y 5, en ese momento en órbita.

Las numerosas presiones de la comunidad científica y profesional, el desarrollo de programas espaciales por parte de otros países, singularmente Francia con su programa SPOT (que llevó a temer por el liderazgo estadounidense en esta línea), el creciente interés por la observación global de los cambios ambientales (al tener ya disponible un amplio archivo histórico de imágenes MSS), y las aportaciones estratégicas de las imágenes Landsat en la primera guerra del Golfo (1991), llevaron a modificar el rumbo de los acontecimientos, asegurando un marco jurídico estable para el futuro del programa Landsat a través de la *Land Remote Sensing Policy Act* de 1992 (Williamson, 2001). Por esta ley, se transfería de nuevo el control del programa Landsat al gobierno federal, en un primer momento al Departamento de Defensa y la NASA, y más tarde al Departamento de Interior (a través del *U.S. Geological Survey*) que se encargaría del archivo y la distribución de los datos, en colaboración con la NASA (encargada del desarrollo del satélite y sensores) y la NOAA (responsable de la operación del satélite y del sistema terrestre). Este acuerdo, forzado también por el fracaso en el lanzamiento del Landsat-6, en 1993, ha permitido poner en órbita con éxito el Landsat-7, seis años más tarde, y garantizar una continuidad en los datos.

Mediante una disposición del año 1994, revisada en 1997 y en 2000, se establecieron las líneas maestras de la política de distribución de datos Landsat, que básicamente cuenta con los siguientes principios: asegurar que los datos brutos estén disponibles a todos los usuarios a precios de coste, sin restricciones y con razonable rapidez; asegurar que EE.UU. mantiene la propiedad de los datos brutos generados por la plataforma; respaldar el desarrollo de aplicaciones comerciales de los datos, asegurar que las aplicaciones comerciales sólo se realizarán por el sector privado; facilitar, en la medida de lo posible, la integración de los sistemas de distribución de datos Landsat con los generados por el programa EOSDIS (Sistema global de observación terrestre), y promover la investigación y el desarrollo de las aplicaciones de la teledetección (http://ldcm.usgs.gov/refdocuments.html). Estas disposiciones han permitido reducir considerablemente los costes de los datos brutos de las imágenes ETM+ (a casi un 10 % del importe de las imágenes TM adquiridas por los Landsat-4 y 5). Muy recientemente (mayo de 2008) se ha anunciado la liberalización de todo el archivo histórico Landsat, desde 1972 hasta la actualidad, lo que permitirá acceder a una valiosísima fuente de información para el análisis de cambios en el territorio.

El principal problema que se presenta ahora es la continuidad de los datos, sin

duda la mejor serie temporal para analizar los cambios territoriales que se han producido en nuestro planeta en los últimos 35 años. Por el momento sólo está aprobada la construcción de un satélite que continúe la labor del Landsat, pero no será lanzado hasta 2011 (http://ldcm.nasa.gov/, último acceso marzo 2008), y tampoco se prevé instalar un instrumento similar al TM en los nuevos satélites meteorológicos de órbita polar. Considerando los problemas de funcionamiento del ETM+, y la práctica cancelación del Landsat-5 (que ha excedido con creces su vida útil), se teme que la pérdida de la serie temporal de imágenes (Goward y Skole, 2005). Parte del problema es que el programa Landsat no ha tenido una entidad operacional que garantice el uso constante de los datos, ya que siempre se ha mantenido en una esfera de investigación (Chuvieco y Justice, 2008). NASA no mantiene misiones operativas, y NOAA no está interesada en escalas medias y grandes. Únicamente el USGS podría servir como garante de operaciones, pero no se ha visto implicado en programas sistemáticos que requieran el uso de los datos.

5.2. El satélite SPOT

Este programa espacial supuso un fuerte impulso a la diversificación de las tecnologías de teledetección, ampliando la oferta a otros países además de EE.UU. El primer satélite SPOT *(Systeme Pour l'Observation de la Terre)* se lanzó en 1986. Desde entonces se han lanzado otros cuatro satélites en 1990, 1993, 1998 y 2002. Todos ellos se han desarrollado en el CNES francés, en colaboración con Bélgica y Suecia. El SPOT orbita a una altitud de unos 822 km, con una inclinación de 98° y un período orbital de 101 min. Cuenta con una órbita heliosíncrona y la duración del ciclo es de 26 días.

Entre las novedades más interesantes de este satélite se contaba la incorporación de dos equipos de exploración por empuje denominados HRV (*Haute Resolution Visible*). Estos dos sensores obtenían imágenes en dos modalidades: pancromática y multibanda (V, R, IRC), con una resolución espacial de 10 y 20 m, respectivamente (tabla 3.2). El área cubierta en cada escena era de 60 km de lado, por lo que estos sensores necesitaban incorporar 3.000 detectores en modo multi-espectral y 6.000 en modo pancromático.

Otra importante novedad que incluyó el satélite SPOT era la capacidad del sensor HRV para variar su campo de visión, gracias a un dispositivo móvil instalado en el equipo óptico, lo que permitió observaciones no verticales, de hasta 27° a ambos lados del nadir. Esto también posibilitaba observar la misma zona en órbitas sucesivas, reduciendo la frecuencia temporal de las imágenes si resultaba necesario (de 26 días a 2-3 días según las latitudes). Además, con esa misma aptitud, el HRV podía adquirir imágenes estereoscópicas, lo que añadía a su potencial temático una clara capacidad topográfica (fig. 3.30). Algunas experiencias de restitución digital permitieron obtener modelos digitales del terreno con escalas de hasta 1:50.000 a partir de imágenes SPOT (Toutin y Beaudoin, 1995). Además del sensor HRV, los siguientes satélites SPOT incorporaban dos equipos de apoyo, el DORIS, que proporcionaba un seguimiento muy preciso de la posición del satélite, y el POAM *(Polar Ozone and Aerosol Measurement)*, incorporado en el SPOT-3, que medía el con-

TABLA 3.2. *Sensores a bordo del satélite SPOT*

HRV[1]		*HRVIR*[2]		*Vegetation*[2]	
1	0,50-0,59 μm	1	0,50-0,59 μm	1	0,43-0,47 μm
2	0,61-0,68 μm	2	0,61-0,68 μm	2	0,61-0,68 μm
3	0,79-0,89 μm	3	0,79-0,89 μm	3	0,78-0,89 μm
P	0,51-0,73 μm	4	1,58-1,75 μm	4	1,58-1,75 μm
		P	0,51-0,73 μm		
Resolución espacial					
1-3	20 m	1-4	20 m/10 m[(3)]	1-4	1.000 m
P	10 m	P	10 m-5 m-2,5 m[(3)]		

1. Sólo en los SPOT-1 a 3.
2. Sólo en el SPOT-4 y 5.
3. Sólo en el SPOT-5.

tenido de ozono, aerosoles, nitrógeno, oxígeno y vapor de agua. Poseía 9 canales comprendidos entre el ultravioleta e infrarrojo cercano (Kramer, 2002).

El lanzamiento del SPOT-4 en 1998 supuso una mejora notable en la carga útil del satélite. El sensor de alta resolución pasó a denominarse HRVIR, incorporando una nueva banda en el SWIR (tabla 3.2). Además, la orientación de las dos cámaras era independiente, lo que le permitía tomar simultáneamente imágenes verticales y oblicuas. Se ha ampliado también la autonomía de grabación. Este satélite también incorpora los equipos DORIS y POAM. El último satélite de la serie, el SPOT-5, lanzado en mayo del 2002 mejoró asimismo la resolución espacial del HRVIR (de 10 a 5 o 2,5 m en el pancromático y de 10 m en el multiespectral, salvo el SWIR

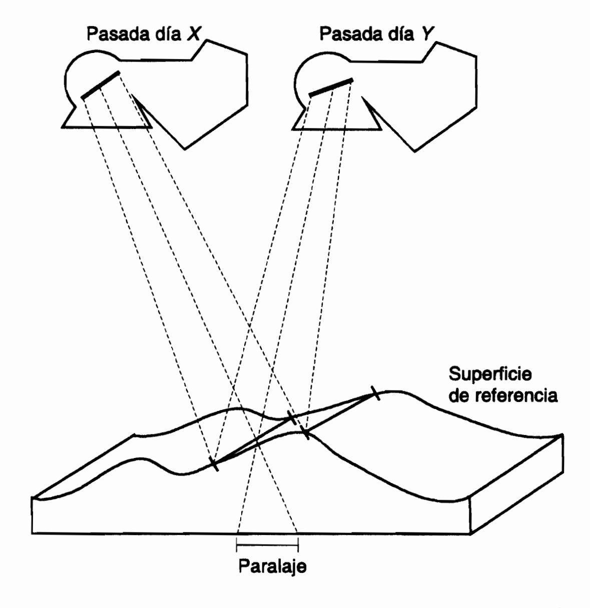


FIG. 3.30. *Sistema de adquisición de imágenes estereoscópicas del satélite SPOT.*

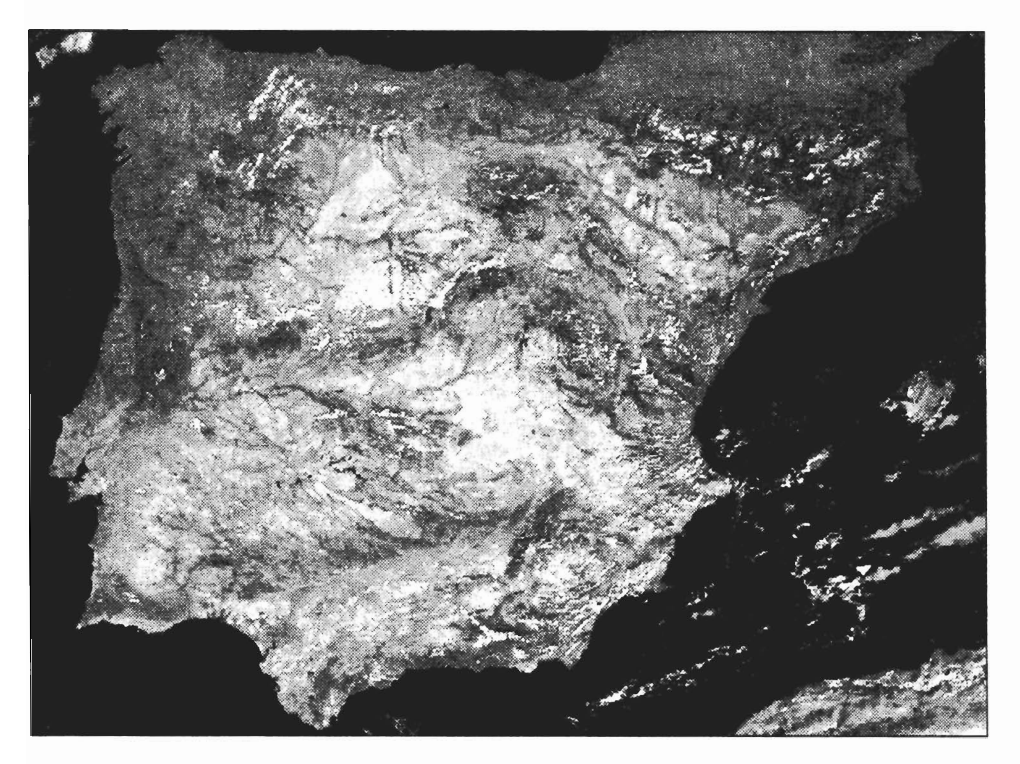


FIG. 3.31. *Imagen* Vegetation *de la Península Ibérica adquirida el 8 de septiembre de 1999. El original en color se encuentra en el archivo cap3.ppt incluido en la web.*

que sigue con 20 m). Estas imágenes se están utilizando actualmente en el Plan Nacional de Teledetección, para obtener una cobertura completa del territorio español, con intención de renovarla cada dos años.

Además de los sensores de mayor resolución, en los SPOT-4 y 5 se ha incorporado otro sensor de carácter más global. Se denomina *Vegetation*, y cuenta con una resolución espacial de 1 km^2, en 4 bandas espectrales (A, R, IRC, SWIR, las mismas que el HRVIR), cubriendo un área de 2.250 km, lo que permite una adquisición diaria sobre todo el planeta (Eastwood *et al.*, 1998). En cierta medida las imágenes del *Vegetation* permiten continuar los estudios que se venían haciendo en los años ochenta con imágenes AVHRR del NOAA, que comentaremos en breve, si bien este sensor cuenta con una radiometría más estable y unas condiciones geométricas de adquisición mucho más favorables que las del AVHRR (fig. 3.31), aunque no cuenta con bandas térmicas.

Al igual que las imágenes del HRVIR, las adquiridas por *Vegetation* se comercializan a través de la empresa *Spot-Image*, que cuenta con acuerdos con distintas antenas receptoras en casi todo el mundo. Para España y Latinoamérica, los centros de recepción se encuentran, en Maspalomas, Fucino y Toulouse, para el Sur de Europa, y México DF, Cotopaxi (Ecuador) y Cuiaba (Brasil), para Sur y Centroamérica.

5.3. EL PROGRAMA IRS

La agencia espacial india (NRSA) ha sido bastante activa en los programas de observación de la Tierra, ya desde los años setenta con la serie Bhaskara. Entre los más modernos destacan los cinco satélites IRS *(Indian Remote Sensing Satellite)*, lanzados hasta el momento (1988, 1994, 1995, 1997 y 2003). El objetivo directo de esta misión es mejorar el conocimiento de los recursos naturales de ese gran país asiático, pero sus imágenes se han utilizado en muchas otras aplicaciones.

En el caso del IRS se opta por la tecnología de exploración por empuje, con dos sensores denominados LISS *(Linear Imaging Self Scanning)* que ofrecen una resolución de 72,5 m (LISS-I) si opera una cámara, y 36,25 m (LISS-II) si operan dos. La superficie cubierta en cada escena es de 148 km para el LISS-I, y de 74 km para el LISS-II, con un ciclo de repetición de 22 días. El sensor LISS facilita información sobre cuatro bandas del espectro, comprendidas entre el azul y el IRC para los dos primeros, y entre el rojo y el SWIR para los dos segundos (tabla 3.3), por lo que resulta idóneo para estudios costeros, discriminación de cubiertas vegetales y exploración minera.

En los dos últimos satélites de la serie (el IRS-1C y 1D) se añadió a este sensor otros dos sensores: una cámara pancromática con alta resolución (5,8 m: fig. 3.32), explorando una zona de 70 km, y un sensor de observación regional, el WIFS, con resolución de 188 m y un área cubierta de 810 km.

Este ambicioso programa de observación de la Tierra indio se ha completado recientemente con dos nuevos satélites. En 2003 se lanzó el IRS-P6, denominado Resourcesat, que cuenta con tres sensores: una cámara de 3 bandas espectrales y resolución de 5,8 m, otra de cuatro bandas y 23,5 m., y una versión mejorada del WIFS, denominada AWIFS, con cuatro bandas y 60 m de resolución. Gracias a abarcar una amplia zona en cada imagen, pueden adquirirse imágenes con bastante frecuencia, lo que le convierte en una buena alternativa para el seguimiento estacional del territorio o la detección de eventos esporádicos (fig. 3.33) a escalas medias. En mayo de 2005 se lanzó el Cartosat-1, que cuenta con dos cámaras pancromáticas con

TABLA 3.3. *Sensores a bordo del satélite IRS*

	LISS-I[1]		*LISS-III*[2]		*WiFS*[2]	*/AWIFS*[3]
1	0,45-0,52 μm	1	0,52-0,59 μm	1	0,62-0,68 μm	0,62-0,68 μm
2	0,52-0,59 μm	2	0,62-0,68 μm	2	0,77-0,86 μm	0,77-0,86 μm
3	0,62-0,68 μm	3	0,77-0,86 μm	3		0,77-0,86 μm
4	0,77-0,86 μm	4	1,55-1,70 μm	4		1,55-1,70 μm
		P[2]	0,5-0,75 μm			
Resolución espacial						
1-4	76,5 m/32,25 m	1-4	23 m[(2)]/5,8 m[(3)]	1-2	188 m	
		P	5,8 m	1-4		60 m

1. Sólo en los IRS-1A y 1B.
2. Sólo en los IRS-1C y 1D.
3. Sólo en el IRS P-6 resourcesat.

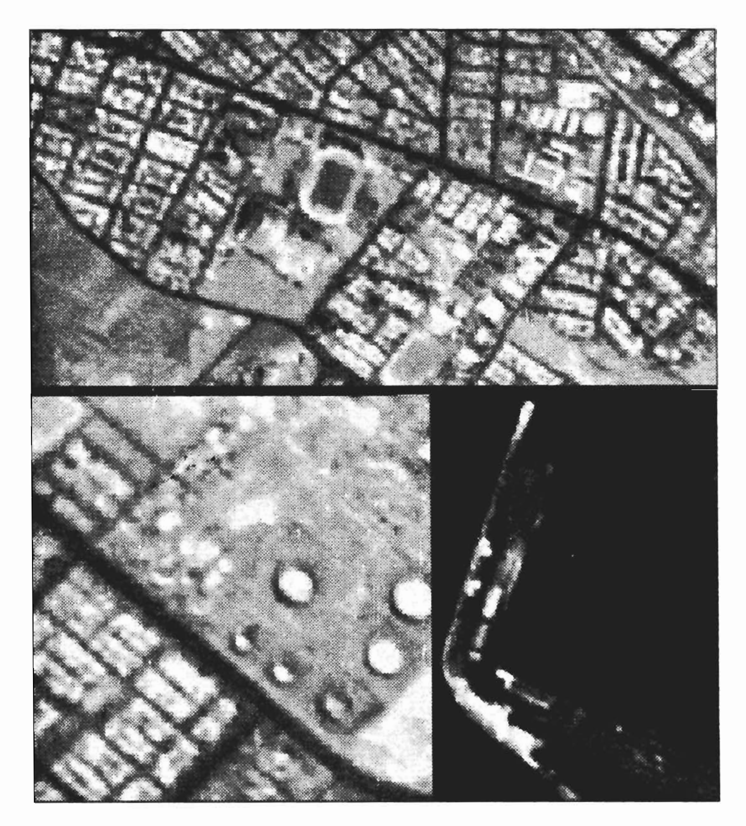


FIG. 3.32. *Fragmentos de una imagen IRS-1C de la ciudad de Arica (Aric00), en el norte de Chile, donde pueden observarse con gran detalle algunos rasgos de la morfología y estructura urbana.*

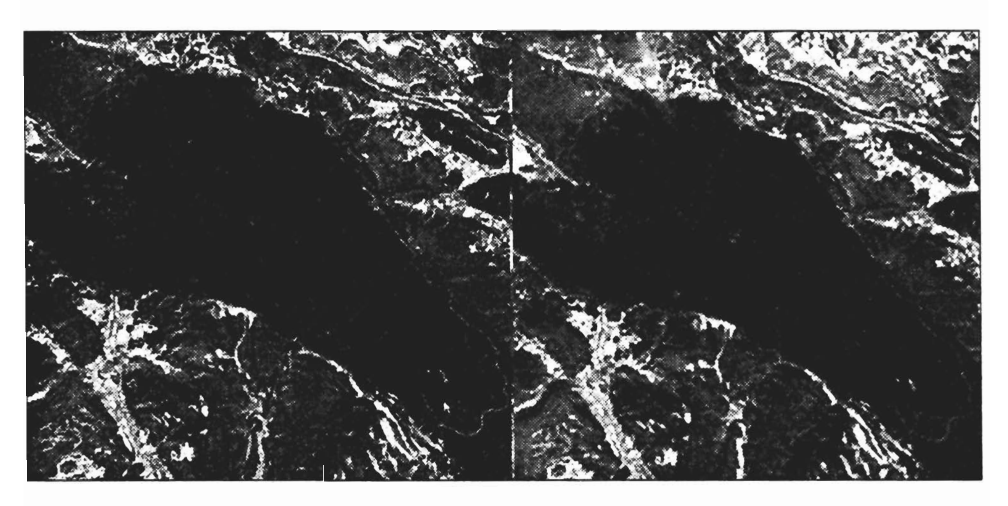


FIG. 3.33. *Comparación entre una imagen TM (izquierda) y AWIFS (derecha) sobre el incendio que afectó a Riba de Saelices (Guadalajara) en julio de 2005.*

una resolución espacial de 2,5 m que adquieren simultáneamente imágenes desde dos ángulos, lo que permite emplear estos datos para observación estereoscópica.

Además de este programa, la agencia india NRSA cuenta con un satélite oceanográfico, denominado IRS-P4 (Oceansat) que se lanzó en 1999. Cuenta con un sensor óptico de 8 canales y resolución de 360 × 236 m, y un radiómetro de micro-ondas con 4 bandas y resolución entre 40 y 10 km.

Las imágenes IRS se comercializan a través de diversas empresas privadas en Europa (GAF) y EE.UU. *(Space Imaging)*. Al tratarse del sensor con mayor resolución espacial disponible hasta hace muy poco tiempo, las imágenes pancromáticas del IRS-1C y D se han utilizado extensivamente en temas urbanos y de inventario forestal. Pese a su baja sensibilidad radiométrica (las imágenes se codifican en 6 bits) todavía resulta una alternativa razonable en tareas de interpretación visual al menos mientras sigan manteniéndose los altos costes de los satélites comerciales de alta resolución.

5.4. Satélites comerciales de alta resolución

Designa este término a una generación de satélites promovidos por consorcios privados que pretenden impulsar la comercialización de imágenes de satélite de muy alta resolución, introduciendo la teledetección en mercados hasta hace pocos años reservados a la fotografía aérea.

Los principales desarrollos en esta línea se han liderado por tres empresas norteamericanas: *Space Imaging* y *Orbimage* (recientemente fusionadas con el nombre de *Geoeye*), y *Earthwatch Inc* (recientemente rebautizada *Digital Globe*), y una israelí. La primera es propietaria del IKONOS y el Orbiew. El IKONOS-2, en órbita desde septiembre de 1999 después de un lanzamiento fallido en 1998, cuenta con una resolución de 1 m en pancromático y 4 m en multiespectral (A, V, R, IRC). El área abarcada en cada imagen es de 11 km, y pueden adquirirse «tiras» de hasta 11 × 1.000 km. Las imágenes se cuantifican en 11 bits de resolución radiométrica, lo que ofrece una alta sensibilidad para discriminar cubiertas terrestres. Los datos se comercializan a través de una red de distribuidores comerciales, pero la recepción de las imágenes está centralizada. La figura 3.34 recoge un ejemplo de las magníficas posibilidades que brinda este satélite para el análisis urbano. *Orbimage,* por su parte, fue un consorcio pionero en lanzamientos comerciales, al poner en órbita en 1995 el Orbview-1, orientado a fines meteorológicos. También es propietario del Orbview-2, que incluye el sensor oceanográfico, el *Seawifs*, en colaboración con la NASA. El *Seawifs* es un radiómetro de 8 canales (entre 0,4 y 0,88 μm), principalmente orientado al estudio del color del océano. Posee una resolución de 1,6 km, y un área abarcada de 2.800 km. Entre los proyectos de alta resolución del nuevo consorcio *Geoeye*, está previsto lanzar en pocos meses el GeoEye-1, dotado con una resolución espacial de 41 cm en el pancromático y 1,64 m en el multiespectral (A, V, R, IRC), con un ancho de observación de 15,2 km y codificación de 11 bits.

En cuanto a la empresa *DigitalGlobe,* se responsabiliza de la operación del Quickbird, que fue lanzado el 18 de Octubre de 2001, tras el fracaso de algún lanzamiento previo. Este satélite incorpora dos cámaras CCD, una pancromática, con

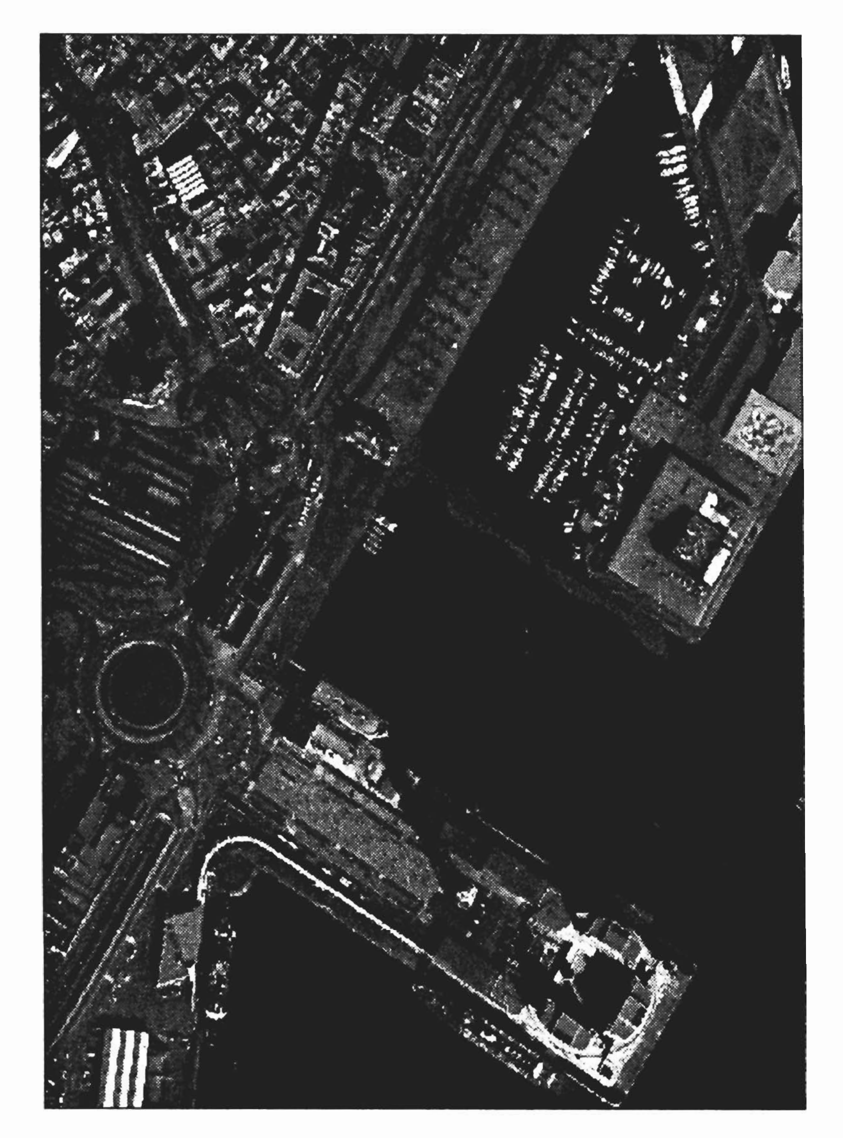


FIG. 3.34. *IKONOS de la ciudad de Barcelona (cortesía Indra Espacio).*

61 cm de resolución espacial (fig. 3.35) y una multiespectral con 2,5 m (A, V, R, IRC). El área cubierta es de 17 km, con «tiras» que pueden llegar a 17 × 225 km. La cuantificación de los datos se realiza en 11 bits por píxel. El período de revisita, para observaciones no verticales, puede reducirse, siempre según datos de la propia empresa, a 1-3,5 días. Recientemente, esta compañía ha lanzado en Worldview-1, continuando en la línea del Quickbird, aunque en este caso sólo cuenta con un canal pancromático a 50 cm de resolución, pero con gran precisión en la georreferenciación. Está previsto lanzar antes de fines de 2008 el Worldview-2, que tendrá una resolución de 46 cm en pancromático y 184 cm en el multiespectral, con 8 bandas entre el A y el IRC.

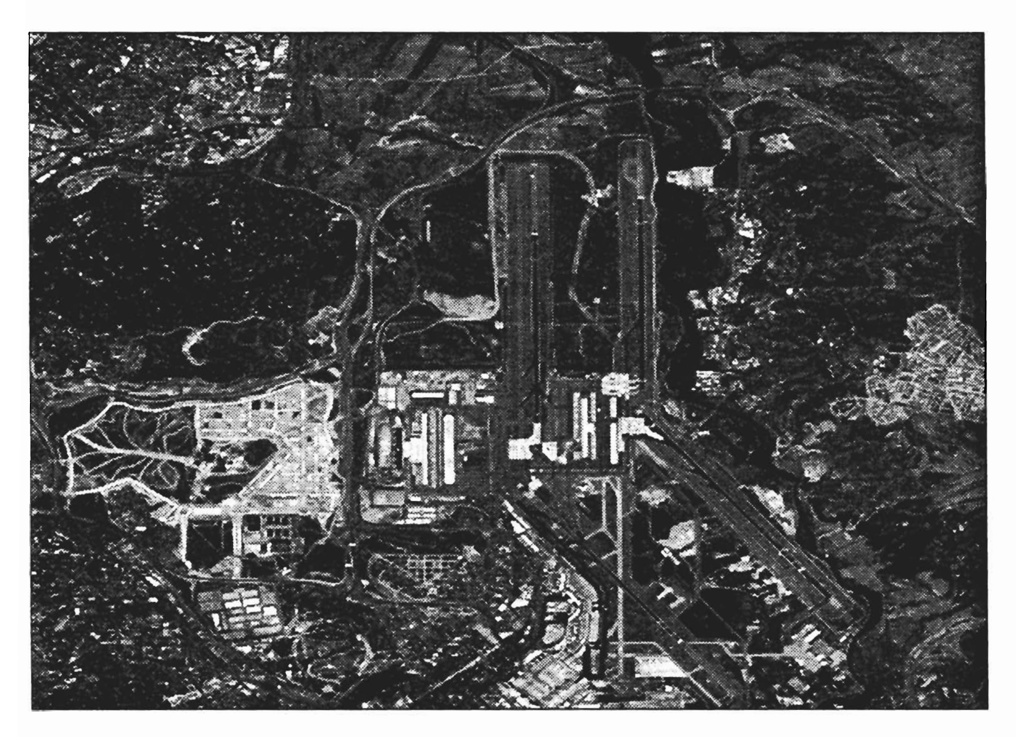


FIG. 3.35. *Imagen Quickbird de los alrededores del aeropuerto de Barajas tomada en agosto de 2007 (http://www.digitalglobe.com/).*

Finalmente, la empresa *ImageSat International*, establecida en 1997 cuenta con participación de varios países, aunque está liderada por un consorcio israelí, y tiene su sede central técnica en Chipre. Lanzó en 2000 el primer satélite de la serie EROS (el A1), que cuenta con una cámara pancromática de 1,8 m de resolución, con un área abarcada de 12,5 km y codificación en 11 bits, y capacidad de cobertura estereoscópica. También se ha lanzado recientemente el EROS B, con una cámara pancromática de 70 cm de resolución con un área abarcada de 7 × 7 km y también con cobertura estereoscópica.

5.5. Tiros-NOAA

Esta familia de satélites constituye uno de los múltiples programas diseñados para enviar información meteorológica a la superficie terrestre. Los satélites meteorológicos son los que cuentan con una mayor solidez en la serie de datos disponible, ya que vienen siendo plenamente operativos desde los años setenta. El primer satélite de la serie se lanzó en los años sesenta, denominándose entonces TIROS. Más tarde pasan a denominarse NOAA *(National Oceanic and Atmospheric Administration Satellite)*, por la agencia meteorológica que los gestiona, a partir del sexto satélite, que se lanzó en 1979.

Teniendo en cuenta que el principal objetivo de esta misión era facilitar infor-

TABLA 3.4. *Características del sensor AVHRR*

	AVHRR/1[1]		*AVHRR/2*[2]		*AVHHRR/3*[3] *Diurna*	*AVHHRR/3*[3] *Nocturna*
1	0,58-0,68 μm	1	0,58-0,68 μm	1	0,58-0,68 μm	0,58-0,68 μm
2	0,72-1,10 μm	2	0,72-1,10 μm	2	0,72-1,10 μm	0,72-1,10 μm
3	3,55-3,93 μm	3	3,55-3,93 μm	3	1,58-1,64 μm	3,55-3,93 μm
4	10,3-11,3 μm	4	10,3-11,3 μm	4	10,3-11,3 μm	10,3-11,3 μm
		5	11,5-12,5 μm	5	11,5-12,5 μm	11,5-12,5 μm
Resolución espacial: todos 1,1 × 1,1, km (en el nadir)						

1. En los satélites pares hasta el NOAA-10.
2. En el resto hasta el NOAA-15.
3. A partir del NOAA-15.

mación sobre el estado actual de la atmósfera, el satélite NOAA se diseñó para ofrecer un ciclo de cobertura muy corto: una imagen cada doce horas en nuestras latitudes. Este ciclo se mejora a seis horas gracias a la sincronización entre los dos satélites que operan simultáneamente. Su altura orbital es de 833 a 870 km, cubriendo en una imagen un área aproximada de 3.000 km de lado.

En lo que se refiere a aplicaciones terrestres, el sensor más interesante del programa NOAA es el denominado AVHRR *(Advanced Very High Resolution Radiometer)* (Cracknell, 1997), diseñado para proporcionar imágenes con una resolución de 1,1 km (en el nadir), en 5 bandas del espectro (R, IRC, IRM, IRT: tabla 3.4). Inicialmente los NOAA con numeración par obtenían imágenes aproximadamente a las 7.30 y 19.30 GMT en el Ecuador, mientras los impares lo hacían a las 14.30 y 2.30 GMT. Actualmente, y debido a diversos problemas en el lanzamiento de algunos satélites, esta regla ya no puede aplicarse. Además, las órbitas se degradan desde el año de lanzamiento, retrasándose incluso considerablemente, lo que conviene tener en cuenta de cara a homogeneizar adecuadamente las series temporales (Privette *et al.*, 1995).

Para asegurar esta frecuencia de adquisición, el AVHRR cuenta con un ángulo de barrido muy amplio (55,4° a ambos lados de la traza), lo que implica notables problemas geométricos y radiométricos en las imágenes resultantes. De esta forma, la resolución espacial del nadir (1,1 × 1,1 km) puede degradarse hasta 2,4 × 6 km en los extremos de la imagen. Esto añadido a los problemas de contaminación atmosférica de los píxeles extremos desaconseja el empleo de los sectores de la imagen que excedan 30° del nadir (Goward *et al.*, 1991). Los problemas de la observación oblicua se ponen especialmente de manifiesto cuando pretendemos generar un mosaico sobre áreas muy extensas, ya que frecuentemente tendremos que contar con imágenes adquiridas en condiciones de observación muy dispares. La figura 3.36, por ejemplo, muestra un mosaico de imágenes AVHRR sobre el Mediterráneo, denotándose con claridad las zonas fronterizas entre imágenes, como la que aparece en el noreste peninsular.

Las imágenes AVHRR se presentan en tres diferentes formatos: la máxima resolución es denominada LAC *(Local Area Coverage)*, cuando se graba a bordo, o

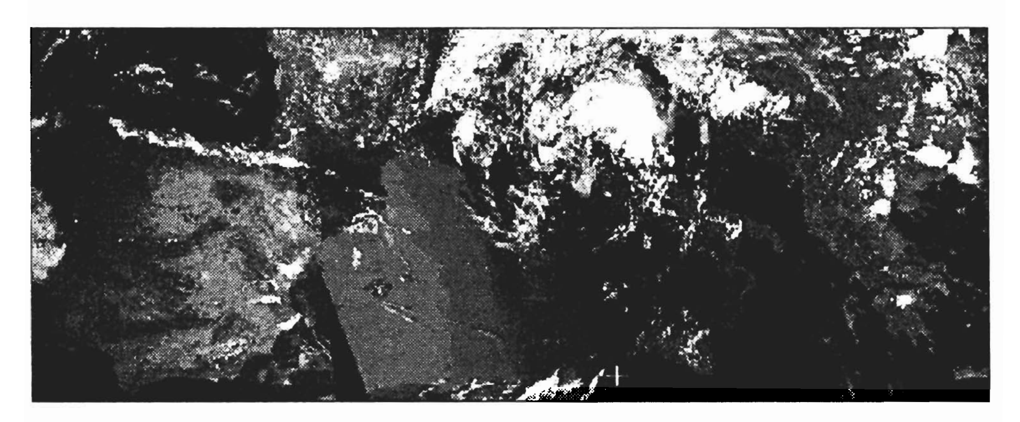


FIG. 3.36. *Mosaico de imágenes AVHRR sobre el Mediterráneo.*

HRPT *(High Resolution Picture Transmission)*, cuando se envía en tiempo real a las estaciones receptoras. Puesto que el sistema de grabación del NOAA es bastante reducido, normalmente sólo se almacena a bordo un producto de menor resolución, llamado GAC *(Global Area Coverage)*, con un tamaño de píxel de 4 × 4 km, que se genera a partir de un muestreo de los datos LAC. Por último, también se produce semanalmente un producto denominado GVI *(Global Vegetation Index)*, calculado a partir de los canales infrarrojo cercano y rojo, para un píxel de 16 km de lado (Kidwell, 1990).

Gracias a su buena cobertura temporal y bajo coste —las imágenes son de libre recepción—, el sensor AVHRR se ha utilizado profusamente en los últimos años, no sólo para aplicaciones climáticas u oceanográficas, sino también para aplicaciones terrestres (Ehrlich *et al.*, 1994). Lógicamente, su resolución espacial no permite emplearlo en estudios de detalle, pero sí resulta muy fructífero para escalas globales (Potter y Brooks, 2000) y regionales (fig. 5*). Al proporcionar información del visible, infrarrojo cercano y térmico, permite seguir las condiciones de la vegetación en períodos cortos de tiempo y a escala global, lo que le hace idóneo para estudiar fenómenos muy dinámicos como la desertificación (Becker y Choudhury, 1988), la deforestación tropical (Malingreau *et al.*, 1989; Shimabukuro *et al.*, 1994), o los incendios forestales de gran magnitud (Chuvieco, 2008*b*; Fernández *et al.*, 1997; Fraser *et al.*, 2000). Asimismo, se está empleando para obtener mapas de la cobertura del suelo a escala continental (Loveland *et al.*, 2000) y para el inventario de cosechas (Teng, 1990). La longitud de la serie temporal (imágenes desde 1979) resulta de gran interés para analizar el impacto del cambio global sobre grandes territorios (Chuvieco *et al.*, 2008*a*). Por ese motivo, se han preparado varios proyectos para ofrecer como libre acceso series temporales de datos AVHRR, homogeneizadas geométrica y radiométricamente. Las más importantes son la Pathfinder (http://daac.gsfc.nasa.gov/guides/GSFC/guide/avhrr_dataset.gd.shtml), con 8 km de resolución espacial, que cubre el período desde 1981 a 1996, la GIMMS (http://glcf.umiacs.umd.edu/data/gimms/), también con 8 km de resolución entre 1991 y 2003, pero sólo disponible para NDVI, y la Long Term Data Record (http://ltdr.nascom.nasa.gov/ltdr/ltdr.html), con resolución de 0,05 grados, desde 1981 hasta la actualidad.

Además del AVHRR el satélite NOAA lleva otros sensores de interés meteorológico como son la sonda TOVS *(Tiros Operational Vertical Sounder)*, el sensor SBUV/2 *(Solar Backscatter UltraViolet Spectral Radiometer*), para medir las concentraciones verticales de ozono en la atmósfera, y el ERBE *(Earth Radiation Budget Experiment)*, con una resolución de 200 a 250 km en el nadir, dedicado al análisis de la radiación global. La sonda TOVS está formada por tres sensores que realizan un perfil vertical de la atmósfera para mediciones de temperatura y, en menor medida, de humedad y contenido total de ozono. Se trata del HIRS/3 (*High Resolution Infrared Radiation Sounder*), que posee un radiómetro de 19 canales en el infrarrojo (3,76-14,95 µm) y 1 en el visible (0,69 µm), con una resolución espacial de 17 km en el nadir; el MSU *(Microwave Sounding Unit)*, radiómetro de microondas con cuatro canales cercanos a los 55 GHz y una resolución espacial de 109 km en el nadir, y el SSU *(Stratospheric Sounding Unit)*, radiómetro infrarrojo de presión modulada con 3 canales en 15 µm y una resolución espacial en el nadir de 147 km. Los sensores MSU y SSU han sido sustituidos en los NOAA-15 y 16 por el AMSU A y B, el primero es un radiómetro de microondas de 15 canales que proporciona sondeos más precisos de temperatura y humedad atmosférica. El AMSU B es un radiómetro de microondas de 5 canales especialmente localizados para realizar mediciones de vapor de agua.

Asimismo, conviene tener en cuenta que existen otros satélites meteorológicos de órbita polar, con características más o menos similares a las del NOAA. Los más conocidos son el ruso METEOR, activo desde 1991, con dos bandas de observación en el VIS y en el IRT, y el chino Feng Yun, lanzado por vez primera en 1988. En las últimas versiones, cuenta con 10 canales (VIS, IRC, SWIR, IRT), una resolución espacial aproximada de 1 km^2, y al igual que el NOAA las imágenes pueden recibirse libremente a partir de una antena receptora de coste medio. Finalmente, conviene considerar que el programa de satélites meteorológicos polares de la agencia europea Eumetsat ha incluido en su primer vehículo, denominado Metop, lanzado en octubre de 2006, un sensor AVHRR, con las mismas características que hemos comentado, además de otros sensores de exploración atmosférica. Esto permitirá continuar la serie de datos de este sensor de modo operacional, ya que pronto será reemplazado en los nuevos satélites polares de la NOAA que se denominarán NPOESS *(National Polar-orbiting Operational Environmental Satellite System)*, y tienen previsto incluir un radiómetro de imágenes avanzado (el *Visible/Infrared Imager/Radiometer Suite*) (Murphy, 2006) más similar al MODIS, que luego comentaremos.

5.6. Satélites meteorológicos geoestacionarios

Los satélites meteorológicos más populares, sin duda, son los de órbita geoestacionaria, ya que son los más utilizados en los medios de comunicación. Estos satélites proporcionan la mayor frecuencia temporal de observación (30 minutos), lo que les hace idóneos para seguir fenómenos atmosféricos muy dinámicos. Actualmente existe una red de satélites geoestacionarios coordinada por la organización meteorológica mundial, a través de su programa GARP *(Global Atmospheric Research*

Programme). Forman parte de esta red los satélites Meteosat, GOES, GMS, Insat y GOMS.

El primer satélite geoestacionario se lanzó en 1966 por la NASA, denominándose ATS *(Applications Technollogy Satellite)*. En forma operacional, este satélite se convirtió en la serie SMS, bautizada como GOES (*Geostationary Operational Environmental Satellite*) a partir de 1975. En el momento presente, se cuenta con cuatro satélites de esta familia, aunque sólo dos resultan operativos. Cubren el conjunto del territorio norteamericano, así como el Atlántico oeste. Los más modernos incluyen varios sensores, entre los que destaca el Imager, sensor de barrido con cinco canales (1 VIS, 2 IRM, 2 IRT), que registra el disco visible de la Tierra cada 30 minutos, ofreciendo una resolución de 1 km para el visible y 4 km para 3 de las cuatro restantes bandas. Además cuenta con otro sensor, denominado Sounder, que ofrece un perfil de temperatura y humedad atmosférica, así como la distribución de ozono.

Similar configuración a la plataforma GOES tiene el satélite europeo Meteosat. Lanzado por vez primera en 1977, hasta el momento se han puesto en órbita seis Meteosat más en 1981, 1988, 1989, 1991, 1993 y 1997, contribuyendo de modo decisivo a la predicción meteorológica en Europa y África. Inicialmente todos ellos se situaban en longitud 0°, pero el Meteosat-3 se desplazó hacia el Oeste para facilitar el seguimiento de huracanes tropicales. Estos satélites cuentan con un sensor de barrido, que ofrece información sobre tres bandas del espectro: 0,4 a 1,1 µm, 5,7 a 7,1 µm y de 10,5 a 12,5 µm. La primera es bien conocida por su aparición en los medios de comunicación. La segunda, se emplea para estudiar el contenido de vapor de agua en la atmósfera, mientras la tercera (térmica) se dirige a la discriminación de tipos de nubes y temperaturas de superficie. La resolución espacial que ofrece es de 2,5 × 2,5 km en el visible y 5 × 5 km en el infrarrojo medio y térmico. La imagen completa del Meteosat cubre el disco visible de la Tierra, desde su posición a 0° de latitud y longitud (fig. 6*). Estos satélites proporcionan imágenes cada 30 minutos. La transmisión se realiza en tiempo real a la estación receptora de Darmstadt (Alemania), en donde se sitúan las oficinas centrales de Eumetsat. Tras algunas correcciones estos datos son enviados a una amplia red de estaciones receptoras, ya sea en alta resolución digital (a las estaciones primarias, *Primary Data User Stations*, PDUS), o en modo analógico.

La nueva generación de satélites Meteosat (MSG, *Meteosat Second Generation*) ha mejorado notablemente la información proporcionada por esta misión. El Meteosat-8 se lanzó en agosto de 2002 y el 9 en diciembre de 2005. Ambos cuentan con sensores muy mejorados sobre los que incluían los primeros satélites de esta familia. El principal sensor se denomina SEVIRI *(Spinning Enhanced Visible and Infrared Imager)* que es un sensor de barrido multiespectral con una resolución temporal de 15 min y proporciona 12 canales espectrales (VIS, IRM e IRT), el visible con una resolución de 1 km y los demás a 3 km (en ambos casos, en el Ecuador: fig. 6*). Esto supone aumentar notablemente el flujo de datos brutos que envía el satélite (de 0,33 Mb/s a 3,2 Mb/s), haciendo más complejo tanto su envío (nuevos sistemas de comunicaciones), como su recepción. No obstante, permite mejorar notablemente el rango de aplicaciones de estas imágenes, no sólo en cuestiones meteorológicas (Sobrino, 2008), sino también en temas ambientales de diverso tipo (Calle *et al.*, 2006).

de cruce por el Ecuador próximas a las 13.30 y 13.30 horas. Tener órbitas próximas permite a estas plataformas recoger información complementaria de algunas variables para mejorar la medición de procesos terrestres y atmosféricos muy variados, además de seguir la evolución diaria de su dinámica (Parkinson *et al.*, 2006).

En este apartado nos centraremos en las dos plataformas principales del EOS. El Terra fue lanzado en diciembre de 1999 y el Aqua en mayo de 2002. Ambos incorporan una gran variedad de sensores, que se complementan para generar variables de gran interés ambiental. Los principales objetivos científicos de esta misión se centran en proporcionar a científicos interesados en procesos globales información crucial sobre la distribución de aerosoles, nubosidad, temperatura terrestre y marina, cambios en los usos/coberturas del suelo y el papel de los océanos en el cambio climático. Los dos satélites no son iguales, el Terra es un poco más pesado, incluye distintos sensores al Aqua y está más orientado a aplicaciones terrestres, aunque las dos misiones comparten algunos sensores. El Terra embarca el MODIS, CERES, MISR, MOPITT y ASTER (más detalles en http://terra.nasa.gov), y en el Aqua se han instalado el AIRS, AMSR-E, CERES, HSB y MODIS (más detalles en http://aqua.nasa.gov). Es importante considerar que la mayor parte de los datos captados por estos sensores son gratuitos y están disponibles en internet, convenientemente calibrados. Revisaremos a continuación los sensores más destacados.

ASTER

El ASTER (*Advanced Spaceborne Thermal Emisión and Reflection Radiometer*) es el único sensor de alta resolución espacial incluido en estos satélites. Fue construido por Japón, que se encarga también de la distribución de datos. Cuenta con 15 canales: 4 con 15 m de resolución (V, R, IRC, IRC), el último de ellos estereoscópico con la misma longitud de onda que el tercero; 6 con 30 m de resolución en el SWIR, y otros 5 en el IRT. Sus objetivos principales son medir las propiedades de las nubes, estudios de vegetación y suelos, temperatura terrestre y topografía. Puesto que se adquieren las imágenes simultáneamente con otros sensores del Terra, una de sus principales aplicaciones es la verificación de resultados obtenidos con sensores menos precisos espacialmente. Es el único instrumento del satélite que no toma datos constantemente, sino sólo durante algunos minutos de la órbita, lo que requerirá varios años de trabajo para construir un mosaico global a la resolución de 15 m (por ejemplo, de cara a obtener un MDT global de todo el mundo).

En la figura 7* se incluye un magnífico ejemplo de las imágenes tomadas por este sensor correspondiente al Estrecho de Gibraltar. La imagen, adquirida en el verano de 2000, cubre un sector de la Bahía de Algeciras, observándose bastantes detalles de la configuración urbana, además del Peñón de Gibraltar. Se aprecian incluso varios barcos que navegaban en las proximidades en el momento de adquirir la imagen.

CERES

El sensor CERES *(Clouds and the Earth's Radiant Energy System)* mide el balance de radiación global terrestre y proporciona estimaciones sobre las propiedades

de las nubes. Se incorpora tanto al Terra como al Aqua, así como al satélite TRMM. Continúa las experiencias adquiridas en misiones previas como ERBE a bordo de los satélites NOAA. Se trata de un sensor con tres canales, VIS para medir la radiación de onda corta, IRT para medir la de onda larga, y completo (de 0,3 a 100 μm) para medir el flujo completo de radiación. En el Terra se han incluido dos equipos que funcionan simultáneamente con dos ángulos de barrido distintos (perpendicular a la traza y circular), lo que le permite obtener un perfil vertical de la atmósfera. Este sensor ya se instaló en la misión TRMM, para el análisis de zonas tropicales; además está previsto que el Terra embarque en el Aqua.

MISR

El MISR *(Multi-Angle Imaging Spectroradiometer)* se incluyó únicamente en el satélite Terra. Se trata de uno de los primeros sensores en proporcionar una cobertura multiangular de todo el planeta. Tiene capacidad de observar simultáneamente 9 ángulos distintos (además del nadir, a 26,1 - 45,6 - 60 y 70°, tanto hacia delante como hacia atrás de la órbita) y 4 bandas espectrales (A, V, R, IRC). Esta configuración le permite realizar estimaciones bastante precisas del espesor óptico de la atmósfera, así como análisis pormenorizados de la cantidad, tipo y altura de las nubes, y del efecto de las condiciones de observación sobre la reflectividad de las cubiertas terrestres. El área abarcada en cada imagen es de 360 km de ancho y la resolución es muy variable, dependiendo del ángulo de observación. En el nadir es de 275 m si bien se remuestrea a píxeles más grandes para coberturas de grandes superficies.

La imagen 3.38 muestra un ejemplo de los datos adquiridos por este sensor. Se trata de una adquisición multiangular sobre las Islas Canarias a 70,5° de visión hacia delante de la trayectoria (izquierda), nadir (central) y hacia atrás (derecha). Puesto que las bandas espectrales son las mismas, la variación de tono es debida únicamente a la diversidad de espesor atmosférico en las tres adquisiciones. Muestra una tormenta de polvo proveniente del Sahara, que resulta mucho más evidente en las adquisiciones oblicuas. La resolución en estas imágenes está degradada a 1 km.

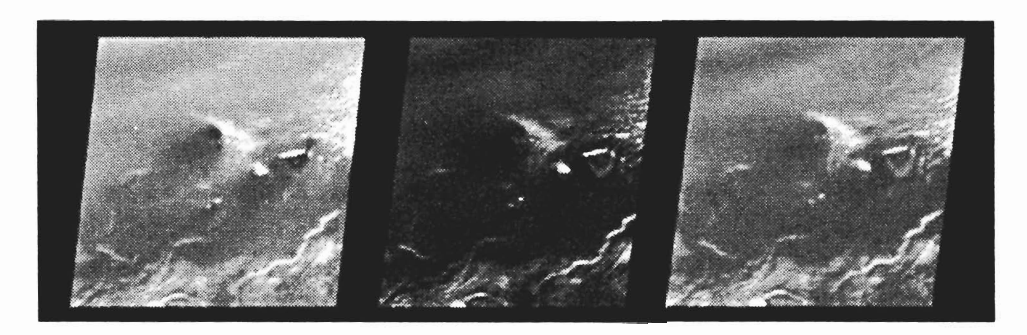


FIG. 3.38. *Imagen MISR de las Islas Canarias tomada el 29 de febrero de 2000. Cortesía NASA (http://visibleearth.nasa.gov).*

TABLA 3.5. *Características del sensor MODIS*

Banda	*Rango espectral (nm)*	*Resolución (m)*	*Banda*	*Rango espectral (nm)*	*Resolución (m)*
1	620-670	250	19	915-965	1.000
2	841-876	250	20	3.660-3.840	1.000
3	459-479	500	21	3.929-3.989	1.000
4	545-565	500	22	3.929-3.989	1.000
5	1.230-1.250	500	23	4.020-4.080	1.000
6	1.628-1.652	500	24	4.433-4.498	1.000
7	2.105-2.155	500	25	4.482-4.529	1.000
8	405-420	1.000	26	1.360-1.390	1.000
9	438-493	1.000	27	6.535-6.895	1.000
10	483-493	1.000	28	7.175-7.475	1.000
11	526-536	1.000	29	8.400-8.700	1.000
12	546-556	1.000	30	9.580-9.880	1.000
13	662-672	1.000	31	10.780-11.280	1.000
14	673-383	1.000	32	11.770-12.270	1.000
15	743-753	1.000	33	13.185-13.485	1.000
16	862-877	1.000	34	13.485-13.785	1.000
17	890-920	1.000	35	13.785-14.085	1.000
18	931-941	1.000	36	14.085-14.385	1.000

MODIS

El MODIS *(Moderate-Resolution Imaging Spectroradiometer)* es el primer sensor con capacidad hiperespectral lanzado al espacio, si bien no se trata de bandas continuas. Cuenta con 36 canales, a distintas resoluciones y ámbitos del espectro (tabla 3.5). Las dos primeras bandas tienen 250 m de resolución, cubriendo el R e IRC. Las 5 siguientes ofrecen 500 m y cubren el V y diversas bandas del SWIR. El resto, con una resolución de 1 km, cubren principalmente el VIS-IRC (por ejemplo, entre 0,4 y 9,965 μm hay 12 bandas), y el IRM y térmico (6 bandas entre 10,78 y 14,38 μm). Cuenta con un área de barrido de 2.300 km lo que le facilita una cobertura prácticamente diaria de la Tierra (fig. 8*).

Una de las novedades más interesantes del sensor MODIS es que tanto las imágenes originales como todos los productos derivados se encuentran accesibles libremente a través de internet. Los productos, además, están calibrados físicamente, y están disponibles los algoritmos que se han empleado en su generación, lo que permite validar sus asunciones y analizar su consistencia. Los productos se van revisando en torno a «Colecciones», que marcan actualizaciones de cada uno en función de nuevos algoritmos de proceso más avanzados, o al detectar algunas anomalías en el funcionamiento. Actualmente hay 45 productos estándar del programa MODIS, cubriendo campos muy variados: reflectividad bruta y corregida, nubes, cobertura de nieve y del suelo, área foliar, productividad vegetal, índices de vegetación, detección de incendios, etc. (Justice *et al.*, 2002; NASA, 2000).

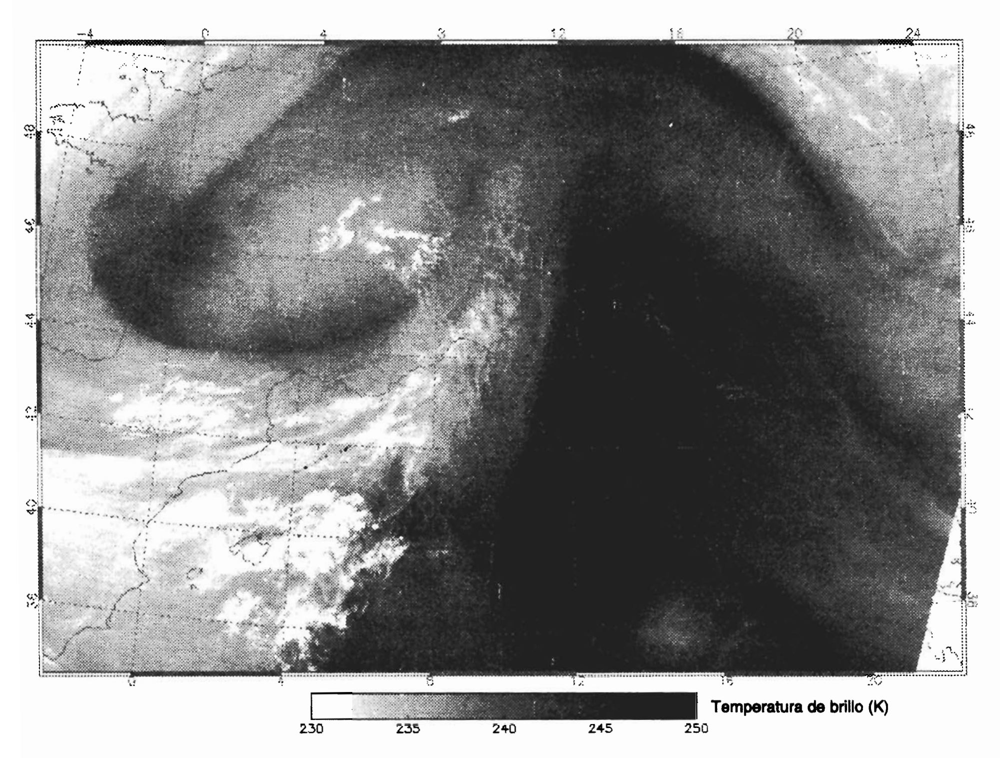


FIG. 3.39. *Imagen adquirida el 7 de marzo por el MODIS correspondiente a la temperatura de brillo registrada en el IRM para el centro y sur de Europa. Fuente: http://visibleearth.nasa.gov.*

Gracias a estas capacidades, las aplicaciones de los datos MODIS que se están abordando son muy numerosas (Chuvieco *et al.*, 2008*b*; Chuvieco *et al.*, 2008c; Hansen *et al.*, 2005; Jin y Sader, 2005; Kelly y Hall, 2008; Korontzi *et al.*, 2006; Stow *et al.*, 2005; Yebra *et al.*, 2008). Los productos pueden obtenerse directamente a través de la red de distribución de datos de la NASA: *Distributed Active Archive Center Alliance*, DAAC: http://daac.gsfc.nasa.gov para datos atmosféricos y http://lpdaac.usgs.gov/main.asp para datos terrestres (último acceso, marzo 2008).

La figura 3.39 muestra un ejemplo de los productos generados por este sensor. Se trata de una imagen correspondiente a la temperatura de brillo del canal 27, situado entre 6,5 y 6,89 µm, que permite determinar la temperatura del vapor de agua. La imagen corresponde al sur de Europa e incluye buena parte de nuestro país, el sur de Francia e Italia.

MOPITT

El MOPITT *(Measurements of Pollution In The Troposphere)* es un sensor primordialmente diseñado para estudiar las condiciones de la baja atmósfera, particularmente cómo interacciona con las superficies terrestres y marinas. Pretende estimar la distribución, transportes, fuentes y sumideros de monóxido de carbono y metano en la troposfera. Utiliza una técnica novedosa (correlación espectroscópica de

gases), midiendo la energía reflejada y emitida desde la Tierra en tres bandas espectrales (en el IRM), que pasa a través de diferentes rutas por unas cápsulas a bordo con monóxido de carbono y metano. Las diferencias observadas en la absorción permiten estimar el contenido en la atmósfera de estos gases. Este sensor tiene una resolución de 22 km en el nadir y abarca un área de 640 km.

5.8. DMSP

Los satélites de la serie DMSP *(Defense Meteorological Satellite Program)* se diseñaron inicialmente con el propósito de facilitar información global y diaria sobre la cobertura de nubes, con fines militares. Dotados originalmente con sistemas de vídeo, a partir de los años setenta se mejoran con equipos de exploración y radiómetros pasivos de microondas. Gracias a la continuidad de la serie (ya están construidos satélites de esta serie hasta 2005), y a su reciente disponibilidad para aplicaciones civiles, se trata de una información de gran interés para la observación global, completando la proporcionada por el AVHRR del NOAA. El DMSP cuenta con varios sensores de exploración meteorológica, dedicados a observar las condiciones de las capas medias y altas de la atmósfera.

Para aplicaciones terrestres, los sensores más interesantes a bordo del DMSP son el SSM/I (*Special Sensor Microwave Imager*), radiómetro de microondas, que completa las medidas realizadas por el Nimbus en los años setenta, y el OLS (*Operational Linescan System*), que es el sensor más importante de la misión. El OLS es un equipo de barrido que proporciona imágenes diurnas y nocturnas en dos bandas: visible (0,5 a 0,9 µm) e infrarrojo térmico (10,5 a 12,6 µm). La resolución espacial puede llegar a 0,56 km, aunque habitualmente se graba sólo una versión degradada, a 2,7 km. Una curiosa capacidad de este sensor es adquirir imágenes nocturnas en el visible, gracias a amplificar notablemente su sensibilidad radiométrica. Esto le permite detectar focos de luz, ya sean urbanos, pozos de petróleo o incendios, obteniendo imágenes muy espectaculares de los patrones urbanos a escala global (Elvidge *et al.*, 1997) y sirviendo de complemento a otros sistemas para la detección de incendios (Elvidge, 2001; Fuller y Fulk, 2000).

La figura 3.40 ofrece una visión global de los núcleos urbanos de la Península Ibérica, tal y como se observan por este sensor a partir de un conjunto de imágenes multitemporales, que permiten eliminar las nubes o áreas con posibles problemas de observación. Resultan evidentes las principales concentraciones de población: Madrid, Lisboa, litoral catalán y valenciano, Sevilla, Granada, el eje asturiano, etc., así como los vacíos demográficos más destacados, Pirineos, Sistema Ibérico y Cantábrico, Sierra Morena, etc.

5.9. Satélites de la Agencia Espacial Europea

Con excepción de los meteorológicos, el primer satélite de teledetección de la Agencia Espacial Europea (ESA) fue el ERS (*European Remote Sensing Satellite*), lanzado en 1991, al que siguió otro similar en 1995. Estos satélites se diseñaron para

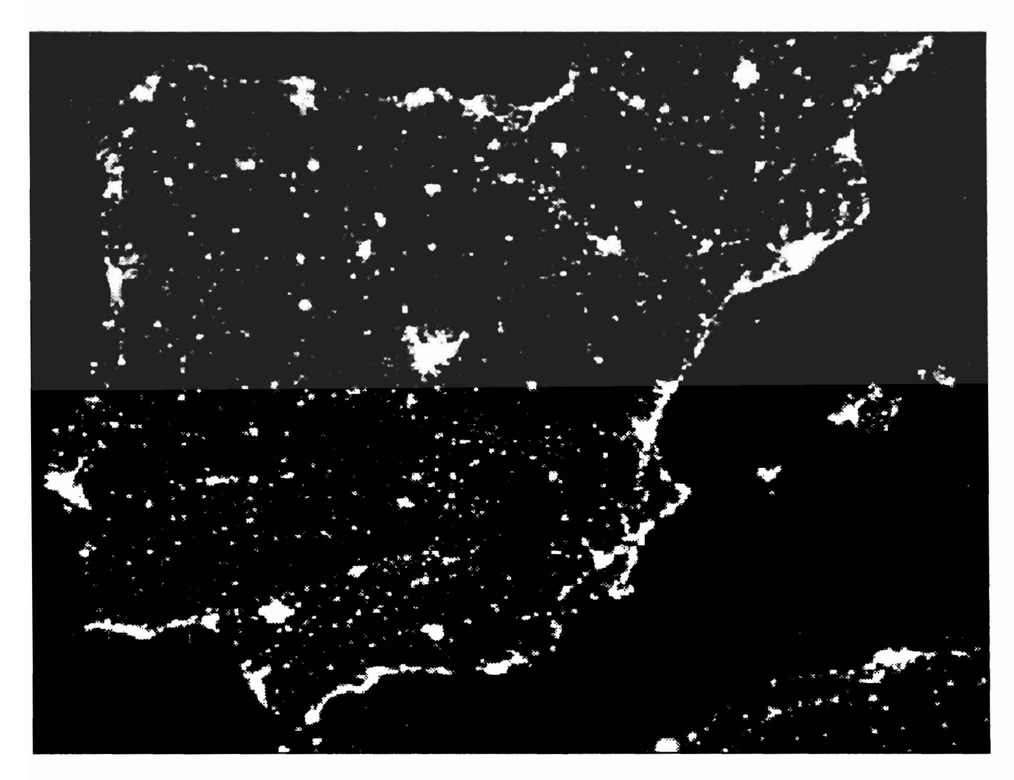


FIG. 3.40. *Imagen DMSP de la Península Ibérica. Cortesía: National Geophysical Data Center.*

complementar la observación proporcionada por los equipos ópticos (instalados a bordo del Landsat ó el SPOT), y se dirigía principalmente al estudio del océano y la criosfera, aunque también se han observado muy interesantes aplicaciones en seguimiento de procesos terrestres. El ERS orbitaba a una altitud de 780 km, medía 12 × 12 × 2,5 m y pesaba 2.400 kg (ESA, 1995).

La carga útil de los satélites ERS se componía básicamente de dos sensores radar y un explorador de infrarrojo térmico. El equipo más importante, sin duda, era el instrumento activo de micro-ondas (AMI, *Active Microwave Instrument*), que incluía un radar de imágenes y un dispersómetro de vientos. El primero se podía utilizar en modo imagen, trabajando en banda C (5,3 Ghz), con polarización vertical semejante y una resolución espacial de 26 m en profundidad y entre 6 y 30 m en acimut. El área cubierta era de 102 km, con un ángulo medio de incidencia de 23°. Como el flujo de datos era muy elevado, sólo se empleaba cuando estaba en el área de alguna antena de recepción terrestre y durante pocos minutos por órbita. Este equipo también podía trabajar en modo «olas», como dispersómetro de vientos para medir el oleaje marino.

El segundo equipo de micro-ondas instalado en los ERS fue un altímetro, trabajando en banda K (13,8 Ghz), que permitía mediciones verticales sobre la superficie marina, lo que fue utilizada para conocer la variación de la altura del mar y el oleaje (fig. 10*).

Finalmente, los satélites ERS incorporaron un equipo de barrido térmico,

denominado ATSR *(Along Track Scanning Radiometer)*, diseñado por un consorcio de empresas inglesas y australianas para proporcionar una medida precisa de la temperatura del agua del mar y del techo de las nubes. Este sensor ofrecía cuatro bandas en el SWIR, IRM e IRT, con una precisión en temperaturas de 0,1 K y una resolución espacial de 1 km en franjas de 500 × 500 km. En el ERS-2, se mejoró un poco este sensor, denominándole ATSR-2, pues incorporaba tres nuevas bandas en el visible e infrarrojo próximo y tenía capacidad de observación con dos ángulos.

Asimismo, el ERS-2 incorporó un nuevo sensor sobre el ERS-1, específico para medir el contenido de ozono en la atmósfera. Se denominó GOME *(Global Ozone Monitoring Experiment)*, y proporcionaba medidas del contenido en la atmósfera de diversos gases (ozono, dióxido de nitrógeno, oxígeno, etc.), mediante una técnica de absorción espectroscópica diferencial.

En 2002 la ESA lanzó su proyecto de observación de la Tierra más ambicioso, el Envisat. Además de continuar las observaciones de los ERS, incorporó numerosos sensores adicionales a los ERS, como el sensor hiperespectral (MERIS), dotado con 15 canales entre el R y el IRC, orientado principalmente a la medición de la clorofila en el agua (fig. 9*), un interferómetro de micro-ondas (MIPAS), un espectrómetro para medición de gases de traza (SCIAMACHY), y un radiómetro para medir el vapor de agua atmosférico (MWR). No obstante, el principal sensor de la misión sigue siendo el equipo activo de micro-ondas, que en esta misión se denomina radar de apertura sintética avanzado (ASAR), con una resolución de 30 × 30 m, trabajando en banda C con 5 modos de polarización. Este sensor está orientado a aplicaciones marinas y seguimiento de capas de hielo y nieve. El Envisat mantiene asimismo un radiómetro térmico (AATSR), dotándole de algunas mejoras sobre las anteriores versiones del ERS.

En un futuro próximo está previsto que la ESA continúe sus programas de observación con las misiones Sentinel, que contarán con equipos ópticos, a distintas resoluciones, y radar.

5.10. Otras misiones Radar

El primer satélite en incorporar un equipo radar para adquisición de imágenes fue el Seasat, lanzado en 1978. Contaba con polarización semejante HH, un ángulo de incidencia entre 20 y 26° y 25 m de resolución espacial. Además, incorporaba un altímetro de bastante precisión. Sus principales aplicaciones eran oceanográficas, de ahí el nombre, principalmente una medición más precisa del geoide marino. Junto a ello, permitió abordar estudios sobre altura del oleaje, detección de bancos de arena sumergidos, corrientes oceánicas, etc. (Elachi, 1982). Pese a la brevedad de su misión —dejó de funcionar a los 99 días de su lanzamiento—, el rango de aplicaciones que ha alimentado es muy amplio. Junto a las oceanográficas, destacan la localización de accidentes geológicos (Koopmans, 1983), cartografía de la cobertura del suelo, de la vegetación y del medio urbano.

La fecunda misión del Seasat se vio ampliada sucesivamente por varios radares de imágenes instalados en el trasbordador espacial norteamericano *(Space Shuttle)*. En concreto, las misiones de este equipo se desarrollaron en los años 1981, 1984 y

1994, con el nombre de SIR-A, B y C, respectivamente. Las dos primeras misiones eran similares al SAR del Seasat, trabajando en la banda L, con resolución de 25 a 40 m, y polarización HH, aunque ofrecían un mayor ángulo de observación: 47° en el SIR-A y 15 a 60° en el SIR-B, gracias, en éste último, a una antena direccionable. También en el SIR-B se introdujo la grabación digital de los datos. El SIR-C superó los rasgos técnicos de sus predecesores, con tres bandas de observación (L, C y X), polarización semejante y cruzada, ángulo de observación variable (de 20 a 55°), resolución de 25 a 30 m y grabación digital.

En orden cronológico el siguiente satélite equipado con un radar de imágenes es el ruso Almaz, lanzado en marzo de 1991, aunque ya tenía un precedente en el Cosmos-1870, que también poseía un SAR trabajando en la banda S y con una resolución en terreno de 20-25 m. Almaz se consideraba un satélite operativo, gestionado comúnmente por la agencia espacial rusa y una serie de empresas privadas de otros países, pero su impacto comercial y científico ha sido muy escaso. Incluía un SAR que trabajaba en banda S, observando una zona de unos 40 × 30 km, con una resolución de 10 a 15 m. El ángulo de incidencia podía variar entre 30 y 60°, y la codificación de los datos era digital.

Más recientemente, junto al ERS merece destacarse el esfuerzo de la agencia espacial canadiense por desarrollar satélites con sensores radar. Fruto de este esfuerzo fue el lanzamiento del RADARSAT-1, en noviembre de 1995. Su objeto era mejorar la disponibilidad de datos radar para aplicaciones terrestres (hasta ese momento, solo el ERS tenía radares orbitales), principalmente la agricultura, seguimiento forestal, hidrología, estudios oceanográficos y costeros. El RADARSAT-1 orbitaba a 798 km de altura con una inclinación de 98,6° sobre el plano ecuatorial. Incorporaba un radar bastante avanzado, que operaba en distintos modos, con variadas resoluciones espaciales, áreas de cobertura y ángulos de incidencia. Lo común a todos ellos es su frecuencia (banda C = 5,3Ghz), idéntica al ERS, y polarización horizontal semejante (HH). La resolución espacial puede variar entre 11 y 100 m, y el área cubierta entre 50 y 500 km. Para el modo estándar de operación, la frecuencia temporal es de 24 días. En cuanto al ángulo de incidencia, puede variar de modo operativo entre los 20 y 50°, alcanzando hasta 10 y 60°, en modo experimental. La figura 3.41 presenta un ejemplo de aplicación de las imágenes RADARSAT-1 al estudio de la contaminación acuática. Se delimitan con claridad unos vertidos de petróleo que afectaron a la costa argentina en enero de 1999. El crudo presenta una señal de retorno más débil que al agua no afectada, al contar con mayor densidad. En diciembre de 2007 se lanzó el RADARSAT-2, que ha mejorado las características de la primera misión canadiense. En este caso, incorpora un SAR avanzado con resolución entre 3 y 100 m, 4 niveles de polarización, dos vistas, mayor resolución temporal y áreas de cobertura entre 20 y 500 km.

Finalmente, conviene considerar en las misiones radar a la agencia espacial japonesa, que puso en órbita en 1992 el satélite JERS-1 con un avanzado SAR. Frente al ERS y RADARSAT, este satélite trabajaba con banda L, por tanto con una mayor longitud de onda, lo que le permitía obtener una información complementaria sobre cubiertas vegetales. Este radar contaba con polarización HH, ángulo de observación de 35° y resolución espacial de 20 m (cubriendo un área de 75 km de lado). Lamentablemente dejó de funcionar en 1998. Recientemente, en enero de 2006, se

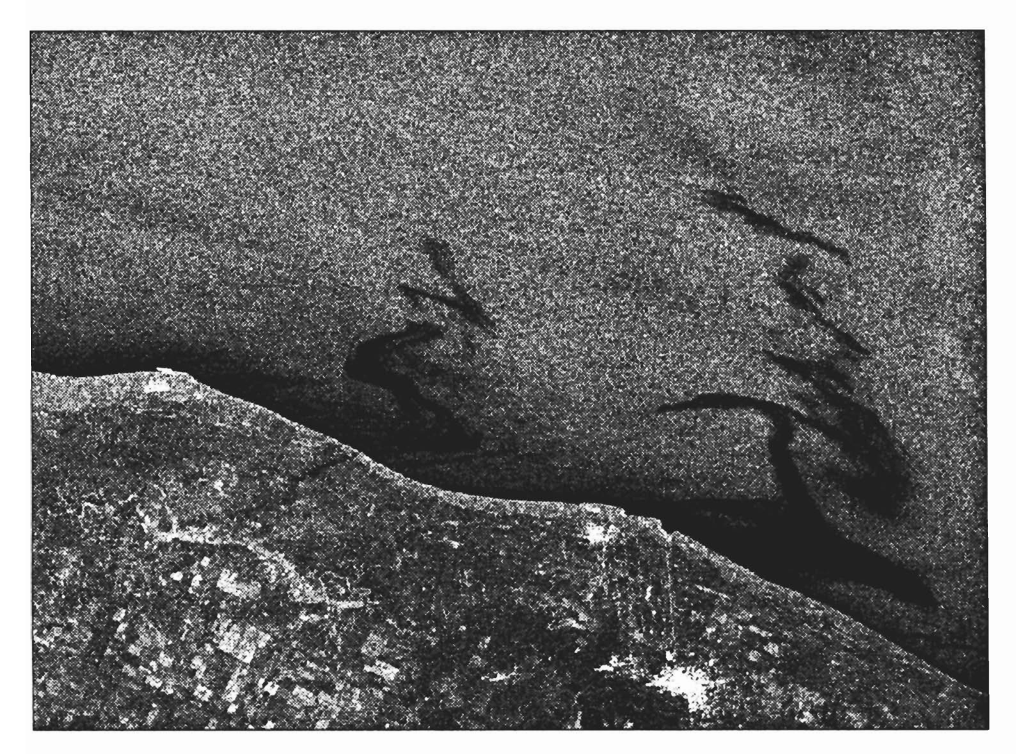


FIG. 3.41. *Imagen RADARSAT de las inmediaciones de la Plata (Argentina) tomada el 26 de enero de 1999. Cortesía DAIS.*

ha continuado esa misión con el lanzamiento del ALOS *(Advanced Land Observing System)*. Este satélite cuenta con tres sensores, una cámara pancromática y estereoscópica para obtener modelos digitales de elevación, un espectro-radiómetro avanzado, y un radar en banda L, denominado PALSAR. *(Phased Array type L-band Synthetic Aperture Radar)*.

5.11. Otros programas con sensores ópticos

La agencia espacial japonesa (NASDA) ha sido bastante activa en programas de observación de la Tierra, a partir de los años ochenta. El primer satélite que lanzó fue el MOS *(Marine Observation Satellite)*, en febrero de 1987, ampliándose la serie con una segunda plataforma en 1990. Se diseñó primariamente para la investigación oceánica, aunque también contaba con interesantes rasgos para su aplicación terrestre. Su carga útil se componía de los siguientes sensores: un equipo de exploración por empuje, bautizado como MESSR *(Multispectral Electronic Self-Scanning Radiometer)*, con una resolución de 50m y cuatro bandas espectrales, dos en el visible y dos en el infrarrojo cercano; un explorador de barrido, denominado VTIR *(Visible and Thermal Infrared Radiometer)*, con una banda en el visible y tres en el infrarrojo térmico (resolución espacial de 900 y 2.700 m, respectivamente); y un ra-

diómetro de micro-ondas, el MSR *(Microwave Scanning Radiometer)*, operando a 23 y 31 GHz, con resolución de 32 y 23 km, respectivamente (Tsuchiya *et al.*, 1987). De estos sensores, el más destacado para estudios medioambientales fue el MESSR, similar al HRV-SPOT en cuanto a tecnología, al MSS en cuanto a resolución espectral, y a medio camino entre éste y el TM respecto a su resolución espacial. Este sensor ofrecía imágenes de 100 × 90 km, con un ciclo de recubrimiento de 17 días. Estuvo activo hasta 1996.

Además del radar, el JERS-1 contó con un radiómetro óptico, denominado OPS *(Optical Sensor)*, que proporcionaba información de 8 bandas en el VIS, IRC, SWIR con 18 m de resolución espacial. La banda 8 proporcionaba cobertura estereoscópica sobre la 3 (0,76 a 0,86 μm). Sin embargo, el proyecto más ambicioso hasta el momento de la NASDA ha sido el satélite ADEOS, activo sólo entre 1996 y 1997 como consecuencia de un fallo en los paneles solares. El satélite incorporaba numerosos sensores de observación ambiental (un radiómetro VIS-IRC-SWIR avanzado, un sensor de color del océano, un dispersómetro, el TOMS, el POLDER, etc.). Esta misión se enriquece con el reciente lanzamiento del ALOS.

La agencia espacial rusa ha sufrido diversas transformaciones en las últimas décadas, debilitándose considerablemente su papel en temas de observación de la Tierra, en gran parte debido a los problemas de comercialización que han tenido sus sensores. Entre los proyectos más destacados figuran los satélites meteorológicos METEOR-3 y GOMS, y los de recursos naturales RESURS y OKEAN. El METEOR incorpora una serie de cámaras de televisión de resolución media-baja (0,7 a 35 km, según los casos), así como algunos equipos diseñados por otros países para obtener perfiles atmosféricos (aerosoles y capa de ozono). El GOMS es un satélite geoestacionario de características muy similares al Meteosat (3 bandas, similar resolución espacial), situado a la longitud de 76° 50′ E. El RESURS tal vez es el de mayor interés, pues ha permitido tomar imágenes a una resolución intermedia entre el Landsat-MSS y el NOAA-AVHRR, siendo de interés para estudios de escala regional y continental. Cuenta con dos sensores de barrido multiespectral, el MSU-E con una resolución espacial mayor, y el MSU-SK, con resolución media (140 m en los canales ópticos, 550 en el térmico), facilitando información del verde, rojo, infrarrojo cercano y térmico.

Además de estas grandes agencias, otros países con menor tradición espacial han lanzado recientemente satélites al espacio, como es el caso de Corea, que lanzó en 1999 su primer satélite de observación de la Tierra, el Kompsat-1, equipado con una cámara pancromática de 6 m y otros sensores oceanográficos, Malasia, Taiwán o Israel. En el ámbito de nuestra área cultural, vale la pena citar el proyecto brasileño-chino, denominado CBERS, y el argentino SAC-C. El primero cuenta con tres radiómetros: WFI, 2 bandas, cobertura regional (890 km) y resolución media (260 m); una cámara de alta resolución (20 m) en 4 bandas espectrales, y un equipo similar al Landsat-MSS, aunque con capacidad térmica y observación en el SWIR. Por su parte el SAC-C, incorpora un sensor de resolución media, con 350 y 175 m y 5 bandas espectrales, así como otros sensores para el análisis de los campos geomagnéticos, sistemas de posicionamiento global y radiación espacial de baja órbita. Estas misiones tendrán continuidad en el inmediato futuro.

5.12. Programas con sensores hiper-espectrales

Tal vez una de las principales novedades tecnológicas que ha irrumpido en la teledetección en la última década sea el creciente empleo de los sensores hiper-espectrales. Se trata de equipos de muy alta resolución espectral que permiten obtener simultáneamente imágenes de un gran número de bandas. Hasta hace muy poco estos equipos eran muy escasos, por lo que los datos disponibles restringían notablemente el rango de aplicaciones. A bordo de aviones, se realizaron algunos estudios en los inicios de los noventa con el sensor HIRIS *(High Resolution Imaging Spectrometer)*, dotado de 192 canales, distribuidos entre el VIS y el IRC. Estos sensores de alta resolución espectral permiten recoger información en bandas muy estrechas, discriminando parámetros críticos de la vegetación o los suelos, que no serían perceptibles con sensores convencionales. A partir de estas imágenes, se obtuvieron variables biofísicas de gran interés para entender mejor el funcionamiento de la fisiología vegetal, como el contenido de clorofila, lignina, nitrógeno o de agua (Curran y Kupiec, 1995), así como algunos minerales presentes en el suelo (Kruse *et al.*, 1993*b*).

La puesta a punto del AVIRIS *(Airborne Visible/Infrared Imaging Spectrometer)* supuso un incremento considerable de este tipo de estudios. Este sensor, que vuela sobre un avión U2 y es operado por el *Jet Propulsion Laboratory* (JPL), facilita 224 canales contiguos, que van desde 0,4 hasta 2,5 μm, codificando los datos en 12 bits a partir de 1995. Esto permite realizar espectros continuos de una gran cantidad de paisajes, con resoluciones que van de 5 a 20 m, dependiendo de la altura de vuelo. La gama de estudios realizados con este sensor es muy amplia, si bien el análisis de rasgos vegetales (Elvidge y Portigal, 1990; Roberts *et al.*, 1997) y de tipos de suelos (Adams *et al.*, 1986; Palacios-Orueta y Ustin, 1996) han tenido una mayor repercusión. Los datos AVIRIS permiten extraer diversos parámetros estructurales de la cubierta forestal, como la edad de la plantación, la importancia del sustrato o el efecto de sombras (Ustin y Trabucco, 2000).

Además del AVIRIS, hay otros sensores hiper-espectrales montados sobre avión. Tal vez los más conocidos son el DAIS *(Digital Airborne Imaging Spectrometer)*, gestionado por el DLR alemán, que es capaz de registrar 79 canales, la mayor parte en el VIS-IRC-SWIR, pero también con algunos en el IRM e IRT; el canadiense CASI *(Compact Airborne Spectrographic Imager)*, con un rango de 288 bandas entre 0,43 y 0,87 μm; y el australiano HyMap, con 125 bandas entre 0,4 y 2,5 μm. Con ser de gran interés, estos sensores son de orientación local, ya que no adquieren imágenes de modo sistemático, sino únicamente en estudios piloto, principalmente orientados a la innovación científica, aunque ya se cuenta también con aplicaciones comerciales de estas técnicas.

Como muestra del interés de esta observación multibanda, hemos incluido una imagen AVIRIS correspondiente a un incendio forestal que ocurrió en el sur de California en 1999 (fig. 3.42). La imagen recoge diversas bandas espectrales del mismo incendio, mostrando el interés que aporta cada una de ellas en la observación del fenómeno. Mientras en las bandas cortas (azul) se observa principalmente el humo, en el IRC puede observarse con claridad el área recientemente quemada, y en el SWIR las zonas activas. En esta banda la dispersión provocada por el humo es mucho menor que en las más cortas, por lo que es perceptible con claridad el frente de llamas.



FIG. 3.42. *Imagen AVIRIS de un incendio ocurrido en el condado de San Bernardino (sur de California) el 1 de septiembre de 1999. Las bandas corresponden, de izquierda a derecha, a 0,5 µm, 1 µm, 1,5 µm y 2 µm (fuente NASA: visibleearth.nasa.gov).*

Aunque para la detección de focos activos, sería más recomendable una banda un poco más larga (3,7 µm en lugar de los 2,5 µm que proporciona el AVIRIS), queda patente el interés de esta región del espectro para localizar el avance del fuego.

En los últimos años estas perspectivas se están ampliando con la puesta en órbita de los primeros sensores espaciales con capacidad hiperespectral. Como antes comentamos, el primero ha sido el MODIS, a bordo de la plataforma Terra. Aunque cuenta con 36 bandas, su carácter hiperespectral es algo dudoso, ya que no permite un registro continuo del espectro, sino diversas bandas aisladas, aunque ciertamente numerosas, de interés para la observación de determinadas variables. Más propiamente hiperespectral sería el MERIS, a bordo del Envisat, aunque sólo ofrece 15 canales. Ahora bien, el que resulta más destacado en esta sección sería el sensor Hyperion, instalado en la plataforma EO-1, lanzada en noviembre de 2000, que proporciona 220 bandas espectrales entre 0,4 y 2,5 µm con una resolución en terreno de 30 m, y un área abarcada de 7,5 × 180 km. El carácter experimental del Hyperion ha reducido mucho su difusión, pero ha sido como un banco de pruebas para evaluar las posibilidades de la teledetección hiperespectral desde satélite, con interesantes resultados en análisis de la vegetación y suelos (Goodenough *et al.*, 2003; Roberts *et al.*, 2003).

Además de albergar al sensor Hyperion, conviene indicar que el satélite EO-1 tiene bastante interés para situar las líneas futuras de desarrollo de los sistemas de observación de la Tierra de la NASA, ya que resulta un prototipo para validar tecnologías que permitan instalar sensores de menor coste y con un mayor apoyo del sector privado. Este satélite es el primero del programa de la NASA para el nuevo milenio. Incluye un equipo de características muy similares al ETM+, denominado ALI *(Advanced Land Imager)*, aunque con mayor resolución espacial (la banda pancromática cuenta con 10 m), y espectral (9 bandas entre el VIS y el SWIR, si bien elimina el canal térmico), y mejor relación señal-ruido. Está construido con tecnologías más económicas que el ETM+, por lo que puede servir como sustituto de este sensor en misiones futuras.

5.13. EL PROGRAMA ESPAÑOL DE OBSERVACIÓN DE LA TIERRA

En los últimos años se ha planteado en nuestro país la necesidad de contar con sensores de observación terrestre para cumplir las expectativas del plan nacional de teledetección. En este marco, se ha propuesto un sistema mixto, compuesto por dos satélites, uno equipado con cámaras en el espectro óptico (VIS, IRC), denominado Ingenio, y otro con tecnología radar, bautizado como Paz. Aún no están cerrados los detalles técnicos de estas misiones, que coordina el Centro para el Desarrollo Tecnológico e Industrial (CDTI), como entidad coordinadora ante la ESA de los programas españoles de observación de la Tierra, pero no cabe duda que supondrán un salto cualitativo en el uso de los datos de teledetección por parte de las administraciones central y regional, además de contribuir al fortalecimiento de la industria del sector.

Segunda parte

LA INTERPRETACIÓN DE LOS DATOS

Capítulo 4

BASES PARA LA INTERPRETACIÓN DE IMÁGENES DE TELEDETECCIÓN

«Éste es un infeliz que viene perdido y es necesario socorrerle, pues todos los forasteros y pobres son de Zeus y un exiguo don que se les haga le es grato.»

HOMERO, *Odisea*

Como ya señalábamos en la introducción, el objeto de esta obra es facilitar el acceso a una técnica que puede ser muy fructífera en la mejor comprensión de diversos fenómenos ambientales. Por tanto, se ha puesto más énfasis en la interpretación que en las técnicas para la obtención de las imágenes. Los capítulos previos se han dirigido a facilitar al lector unos datos básicos que le permitan precisamente que la interpretación de las imágenes sea más honda, de tal forma que cada uno pueda extraer información relevante de los datos adquiridos para su propio ámbito de interés. En este capítulo se presentan algunas ideas introductorias, que pueden ser útiles en el momento de proyectar una aplicación temática a partir de los datos suministrados por sensores espaciales. Parece lógico que antes de abordar la interpretación propiamente dicha se consideren una serie de cuestiones de cara a mejorar la organización de un proyecto que requiera de esta técnica. Los aspectos más destacados hacen referencia al tipo de sensor o de tratamiento más conveniente para la aplicación que se persigue.

En la organización de un proyecto las decisiones se basarán principalmente en dos aspectos: 1) los objetivos del proyecto, y 2) los medios disponibles para su realización. Lógicamente, los objetivos del trabajo orientan la mayor parte de las decisiones consiguientes, como son las relativas al tipo de información necesaria, a su precisión, escala y nivel de desagregación. Por su parte, los medios disponibles implican un equilibrio entre lo deseable y lo posible, restringiendo el método más idóneo para abordar los objetivos marcados, ya sea en lo que se refiere a las imágenes disponibles para el análisis, ya a los medios para su interpretación. Antes de revisar la relación entre objetivos y medios, vamos a comentar algunos aspectos preliminares que pueden ayudar a mejorar el uso de las imágenes en un entorno de planificación ambiental, destacando algunos problemas que limitan esa utilización.

1. Limitaciones para el empleo de la teledetección

1.1. Información que brindan las imágenes

Cualquier neófito en teledetección debería tener presente que es una técnica con limitaciones, válida para resolver un determinado número de problemas. Obviamente, no es una panacea que solucione todas las necesidades de información sobre el medio ambiente que se requieren actualmente. Falsas expectativas pueden conducir a falsas conclusiones, arribando al polo opuesto; esto es, a concebir la teledetección espacial como una técnica más vistosa que eficaz. Para evitar ambos extremos, cualquier proyecto de aplicación debería comenzar cuestionándose si la teledetección puede solventar el objetivo marcado y si la información que ésta ofrece no está disponible por otros medios más rápidos o económicos.

La respuesta no siempre es sencilla. El rango de aplicaciones de la teledetección está en constante crecimiento gracias a las innovaciones en los equipos sensores y en los métodos de tratamiento. Sin embargo, parece lógico que un trabajo de aplicación se base en un soporte previo, en donde proyectos de investigación precedentes hayan demostrado la validez de una determinada metodología. A este respecto, existe ya un buen grupo de estudios en donde la teledetección espacial está reconocida como una fuente primaria de información, como son la cartografía de la cobertura del suelo, la estadística agraria, la oceanografía o la predicción meteorológica, entre otros muchos. Otra serie de aplicaciones se encuentran aún en fase de experimentación, como es el caso del inventario del volumen de nieve, la detección de contaminantes aéreos o los cálculos demográficos. Por último, otros proyectos son aún inviables con los sensores actuales, ya sea por el nivel de precisión que exigen (inventario ganadero o de animales silvestres), ya por falta de la resolución espacial, temporal o espectral necesaria (detección operativa de incendios, detección de aerosoles). En cualquier caso, una inspección a la amplia bibliografía disponible evitará concebir esperanzas irreales y realizar gastos innecesarios.

1.2. El coste de la información geográfica

Otro aspecto que dificulta el diálogo con usuarios finales de la teledetección es la frecuente percepción de que se trata de una técnica cara, que requiere inversiones elevadas, o implica procedimientos de trabajo que se apartan de los mecanismos de producción ya establecidos. En términos generales, el coste de adquisición de las imágenes es una función inversa de su resolución espacial. Las imágenes de baja resolución suelen facilitarse libremente, mientras los costes se van haciendo mayores según avanzamos a resoluciones más detalladas (fig. 4.1). Adquirir una imagen IKONOS resulta una fuerte inversión si lo comparamos con adquirir fotografías aéreas, de un vuelo ya realizado, a similar escala. Ahora bien, además de que los costes de estas imágenes de alta resolución bajarán en un inmediato futuro —con la llegada de otros sensores de similares prestaciones—, cuando se comparan costes con la fotografía aérea no se consideran los propios de la planificación y ejecución del vuelo, ni lo que supone la oportunidad de tener los datos en un momento determi-

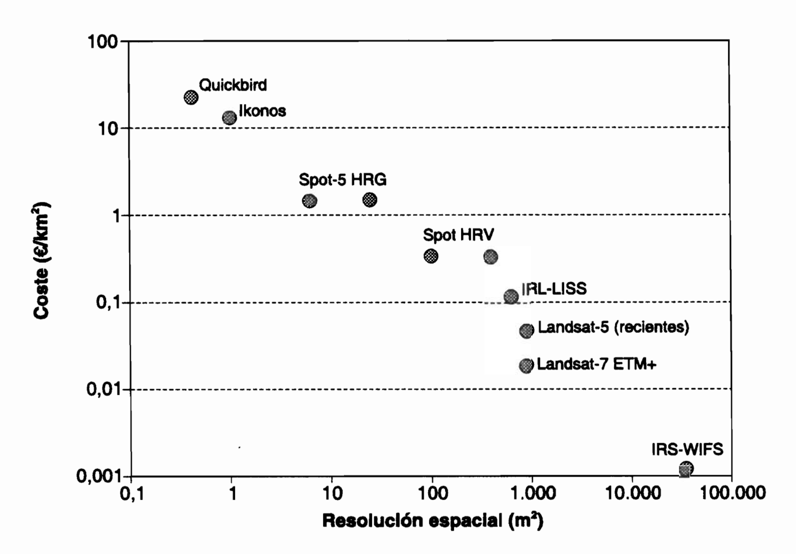


FIG. 4.1. *Relaciones entre coste por superficie y resolución para algunos sensores de teledetección. Precios de referencia de 2007. Escalas logarítmicas en ambos ejes.*

nado y con un formato específico. Algunos autores han planteado comparaciones entre las dos fuentes de información, siendo claramente ventajosa la teledetección cuando nos referimos a espacios suficientemente grandes (Martínez Vega, 1996; O'Connell y Lachman, 2001).

En cualquier caso, aunque la inversión sea objetivamente costosa, no hemos de perder de vista que no disponer de ella puede resultar, a la larga, mucho más caro, pues la falta de información implica decisiones que pueden ser poco adecuadas, mientras una planificación acertada del territorio supone a la larga grandes beneficios, también económicos. Además, y en el caso de la gestión de desastres naturales, la falta de datos puede acentuar las consecuencias catastróficas de estos eventos, anular o hacer ineficaces las medidas de mitigación, y dificultar la recuperación de los espacios afectados (Baker, 2001).

Las tendencias más recientes apuntan a una distribución de información captada por teledetección mucho más abierta. Por ejemplo, la política de datos de NASA (Chuvieco y Justice, 2008; Parkinson *et al.*, 2006) tiende a facilitar las imágenes gratuitamente a través de servidores de internet especializados, asegurando que la inversión realizada en el proyecto tenga el mayor impacto social posible. Esta actitud está impregnando también a otras agencias espaciales, como es el caso del INPE brasileño, que facilita gratuitamente las imágenes adquiridas por el satélite CBERS.

En este sentido, resulta de gran interés el creciente desarrollo de los servidores de imágenes, en donde el usuario puede consultar, o incluso descargar gratuitamente, una serie de imágenes de archivo. Para imágenes Landsat, merece especial mención el servidor del *Global Land Cover Facility* (GLCF: http://glcf.umiacs.umd.edu/index.shtml, último acceso abril de 2008), que incluye imágenes Landsat de todo el planeta libremente accesibles, junto a otras MODIS y varias capas de información auxiliar.

Otro buen ejemplo de políticas distribuidas de datos es el Plan Nacional de Teledetección, que coordina el Instituto Geográfico Nacional y aglutina a múltiples instituciones de la administración nacional y autonómica para compartir los costes de adquisición de los datos, asegurando coberturas sistemáticas, en condiciones idóneas de procesado y disponibles públicamente. El plan pretende cubrir distintas escalas, desde la muy alta (con fotografía aérea digital) hasta la media y baja. En este proyecto se incluye también la creación de un servidor histórico de imágenes Landsat que cubra todo el país.

Un ejemplo más genérico de esta perspectiva de la teledetección a los servicios de información la brinda el programa Google Earth, el más popular servidor de imágenes construido hasta la fecha (Butler, 2006). Se trata en realidad de un servicio operativo para posicionarse sobre el terreno, mejorando la visualización que facilitan los mapas electrónicos convencionales. Lógicamente, ese servicio tiene un valor añadido, la posición de los negocios vecinos, sirviendo como un catálogo espacial de actividades económicas. Además, permite incluir información a los usuarios, enriqueciendo así las capas de información disponibles. La base de las imágenes incluidas en este servidor corresponden a los satélites Landsat (para cobertura global) y Quickbird (para coberturas locales, restringido principalmente a ámbitos urbanos).

1.3. El diálogo con los usuarios

Cualquier innovación tecnológica precisa de un cierto tiempo para que vaya impregnando las estructuras institucionales y los hábitos personales de trabajo. Como cualquier otra novedad, también la teledetección ha ido aceptándose paulatinamente, aunque a veces llama la atención que todavía esté tan poco extendida. Junto a las limitaciones antes apuntadas, también este lento progreso haya podido deberse a falta de diálogo entre los expertos y los usuarios finales de una determinada aplicación, que lleva o bien por parte de ellos a no comprender adecuadamente las posibilidades de la técnica, o bien por nuestra parte a no conocer con detalle sus requerimientos.

En lo que a los expertos se refiere, esta reducida interacción con el usuario ha podido llevar en ocasiones a «sobre-vender» la técnica, sin subrayar adecuadamente las limitaciones actuales de la misma, o sin comprender adecuadamente los requisitos operativos que demanda el usuario. Por ejemplo, los gestores de la prevención y el combate de incendios forestales difícilmente entenderán que les ofrezcamos una cartografía del peligro de incendio exclusivamente a partir de teledetección, cuando nos estamos refiriendo, en el mejor de los casos, a una sola variable relacionada con el peligro (el estado hídrico de la vegetación), dejando a un lado otras variables críticas en el inicio y desarrollo de un incendio, como pueden ser el viento o la humedad relativa del aire que son, hoy por hoy, difícilmente generables a partir de teledetección. Probablemente, sería más fácil que estos usuarios potenciales aceptaran el interés de la técnica si les ofrecemos únicamente lo que podamos generar a partir de las imágenes, subrayando el interés de integrar esa información con la procedente de otras fuentes.

Esto también afecta al desarrollo de misiones específicas de teledetección, orien-

tadas a una determinada comunidad de usuarios. Siguiendo con el mismo ámbito de incendios forestales, si pretende utilizarse operativamente la teledetección espacial en la detección de incendios se requeriría una frecuencia de adquisición de imágenes que sólo proporcionan actualmente los satélites meteorológicos, si bien a un nivel de detalle excesivamente grosero para aquellos países que necesitan un sistema de alerta temprana. Por tanto, si se plantea emplear esta técnica como alternativa realista a la vigilancia terrestre, necesitamos contar con un sistema espacial diseñado *ad hoc* para esta finalidad, que satisfaga las necesidades reales de esta comunidad de usuarios. Ahora bien, ese tipo de misiones son muy costosas, y tal vez no sea abordable financieramente si esa comunidad de usuarios es pequeña, por lo que en teledetección han primado las misiones generalistas (muchos usuarios), sobre las particulares, limitando a la postre las aplicaciones operativas de la teledetección. Tal vez la excepción más notoria a esta regla son los satélites meteorológicos, que cuentan con un grupo de usuarios muy sólido, aglutinados en torno a la agencia EUMETSAT, que permite diseñar misiones operativas ajustadas a sus necesidades y con suficiente continuidad en el tiempo (satélites METEOSAT y METOP).

En cuanto a mejorar el diálogo con los usuarios, se está enfatizando en los últimos años la importancia de implicarlos en cualquier proyecto de investigación y desarrollo, pues facilitan una orientación de gran interés para poner esas tareas en un contexto más realista.

2. Variables y tipos de interpretación

Sintetizando mucho las cosas, puede afirmarse que las imágenes de satélite nos facilitan dos tipos de variables (Jensen, 2000):

— *Primarias*, aquellas que se relacionan directamente con los datos obtenidos por el sensor; esto es, que influyen primariamente en la señal registrada en la imagen.
— *Secundarias* (Jensen las denomina híbridas), que se derivan de las primeras mediante algún tipo de conceptualización.

Las variables primarias son exclusivamente cuantitativas, ya que la señal recogida por el sensor corresponde a una variable numérica (radiancia espectral, altura), que está, a su vez, influida por esas variables biofísicas. Por ejemplo, la temperatura modifica la radiancia emitida en el IRT, por lo que la señal que el sensor recoge en esa banda del espectro será una función de la temperatura y, en definitiva, ésta será extraíble de aquélla (como veremos en 6.6.2.4). Lo mismo podemos decir de otras variables que explican directamente la reflectividad o la emisividad de una cubierta (clorofila, contenido de agua, evapotranspiración, composición mineralógica, humedad, etc.). Cuando el sistema de teledetección utiliza otras tecnologías, pueden detectarse también variables de posición y altura (a partir de estereo-restitución, de interferometría para radar o análisis de distancias, para lídar).

Por su parte, las variables secundarias corresponden a un segundo nivel de abstracción, realizado habitualmente mediante una elaboración de varias de las anteriores. Por ejemplo, podemos deducir el grado de estrés hídrico de las plantas a partir

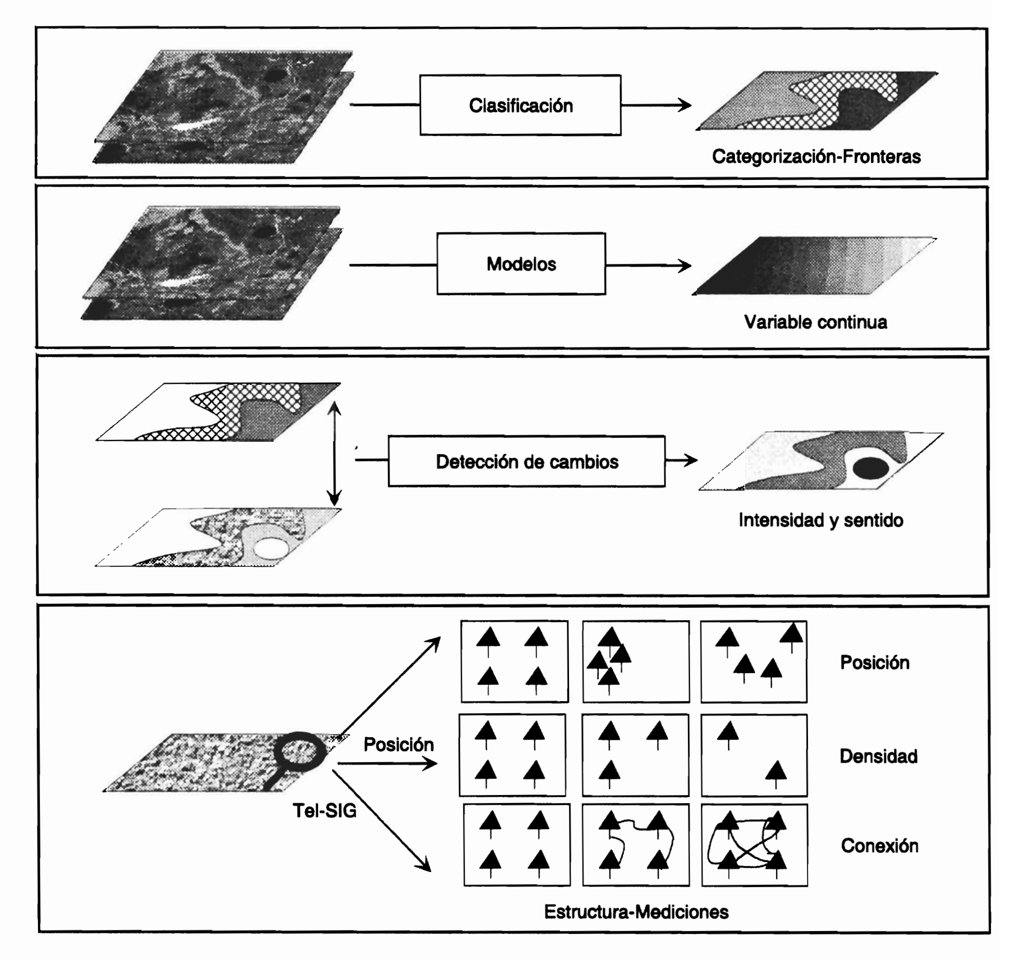


FIG. 4.2. *Tipos de análisis que pueden abordarse en una imagen de satélite.*

de medir su contenido de agua, de clorofila o temperatura, pero el estrés en sí no se mide directamente. De igual forma, la identificación de una determinada cobertura del suelo viene dada por medir su reflectividad en distintas bandas del espectro, junto a sus propiedades texturales y espaciales (forma, tamaño, etc.).

Esta discusión nos lleva a plantear los distintos tipos de interpretación que pueden aplicarse a una imagen adquirida por teledetección, según el tipo de documento que quiere obtenerse. A nuestro juicio, a partir de una imagen se pueden generar cuatro tipos de productos (fig. 4.2):

1. *Cartografía temática.* Se trataría, en este caso, de asignar cada elemento de la imagen en una categoría homogénea, ya sea mediante interpretación visual o digital. En pocas palabras, este enfoque tiene por objetivo asignar cada píxel a una de las clases temáticas objetivo. Ésta ha sido la aplicación más común del análisis de imágenes, en clara herencia de la foto-interpretación clásica. Ya desde los primeros años de vida del sensor Landsat-MSS, las aplicaciones más comunes de estas imá-

genes se dirigían a obtener el inventario y cartografía de un determinado fenómeno: cobertura del suelo, litologías, tipos de nieve, etc. Suponiendo que la asignación de píxeles a categorías sea correcta, este enfoque presupone que cada píxel es homogéneo —ya que se etiqueta con un sólo valor— y, por tanto, se asume de alguna manera que existen transiciones bruscas en el espacio. Supongamos que un píxel se cataloga como arbolado y el vecino como matorral; lo habitual será que en el terreno ambos cuenten con las dos cubiertas, en mayor o menor proporción, pues los cambios de vegetación son graduales. Aunque los métodos más recientes de clasificación permiten asignaciones múltiples (ver 7.1.6.3 y 7.2.3.7), es obvio que cualquier intento de agrupación implica una partición más o menos rígida del espacio, con el riesgo que eso lleva consigo en variables muy continuas en el terreno.

2. Un segundo enfoque considera a las imágenes de satélite como una matriz de medidas numéricas de una variable de interés, por lo que podrían utilizarse para obtener una representación espacial de dicha variable (las que hemos denominado primarias), o de alguna relacionada con ella (variables secundarias). Bajo esta óptica, la exploración que realizan los equipos sensores se concibe como un procedimiento para muestrear sistemáticamente una determinada variable de interés ambiental. La densidad del muestreo vendría marcada por la resolución espacial del sensor (cada cuántos metros tenemos un dato). Aun en el caso de los satélites meteorológicos de peor resolución espacial, ese muestreo es mucho más denso que el que puede realizarse desde estaciones meteorológicas u otros sensores terrestres. Por ejemplo, para obtener la temperatura de la superficie marina antes de contar con satélites de teledetección se realizaban interpolaciones a partir de mediciones puntuales relativamente distantes (donde están situadas las boyas, o donde se toman perfiles por barcos oceanográficos). Con la observación espacial, se toma un dato de radiancia emitida por el agua a intervalos relativamente cortos (incluso en sensores de resolución baja, como el AVHRR, tenemos un dato cada kilómetro cuadrado), que puede convertirse en temperatura de superficie para obtener una imagen mucho más precisa de las variaciones térmicas en el océano. De la misma forma, puede hacerse con otros parámetros como la salinidad o la clorofila del agua (fig. 10*), ofreciendo una imagen mucho más certera de la realidad. En este enfoque de interpretación, la teledetección se orienta a generar variables biofísicas, mediante algún modelo que relacione las medidas del sensor con dichas variables (ver 7.1). Obviamente, este enfoque sólo está disponible cuando tenemos información digital y calibrada, esto es, cuando hay una relación consistente entre los datos de la imagen y una variable física determinada (radiancia espectral, ordinariamente). No está disponible, por tanto, con sensores fotográficos, en donde el tono sólo refleja de modo cualitativo la energía detectada originalmente por el sensor.

3. *Determinación de cambios.* Como ya hemos indicado, una de las principales ventajas de la teledetección espacial es su capacidad para seguir fenómenos dinámicos, gracias a la cobertura cíclica que proporcionan. Esta capacidad resulta de gran interés para inventariar ciertos procesos ambientales: crecimiento urbano, desecación de humedales, efectos de incendios o plagas, etc. Bajo esta óptica, el fin del análisis no es tanto establecer fronteras entre categorías, como señalar aquellas zonas de la imagen que han modificado sensiblemente sus rasgos espectrales entre dos o más fechas. Esa detección de cambios podía hacerse sobre imágenes previa-

mente clasificadas o, de modo más habitual, sobre transformaciones de las bandas originales. En este segundo caso, el cambio puede medirse en una escala continua, ya que las imágenes de partida son cuantitativas y por tanto las técnicas aplicadas pueden también serlo (diferencias o cocientes entre fechas, regresión, componentes principales: ver cap. 7.3).

4. Finalmente, las imágenes de satélite pueden también considerarse como una representación del mosaico espacial de un determinado territorio, por lo que servirían asimismo para medir las relaciones geográficas entre las manchas que lo forman. Bajo este punto de vista, la imagen nos permitiría medir la textura o diversidad espacial de la ocupación del suelo, la forma de las parcelas, sus conexiones espaciales, etc., aprovechando el carácter digital de la imagen (ver cap. 7.4).

3. **Organización de un proyecto de teledetección**

Supuesto que el objetivo de nuestro trabajo sea abordable a partir de sensores espaciales, deben definirse una serie de aspectos para explicitar el tipo de información y de tratamiento que se aplicará en el proyecto. En este sentido conviene considerar, entre otros aspectos, qué sensor resulta más adecuado para los requisitos solicitados, cuántas imágenes se requieren, de qué fechas, qué métodos de análisis se aplicarán, y qué papel tendrán los trabajos de campo. Como hemos comentado antes, un adecuado equilibrio entre los requerimientos y los medios disponibles (fig. 4.3) garantizará un uso atinado de esta tecnología.

3.1. Definición de objetivos

La definición de objetivos resulta crucial a la hora de plantear un proyecto de teledetección, ya que los requisitos marcan notablemente las decisiones que habrá que tomar sobre el material más idóneo para conseguirlos (sensor, número de imágenes, fechas, etc.) y la metodología de trabajo.

Resulta frecuente, especialmente en el entorno de la actividad empresarial, que el usuario de la teledetección se vea obligado a organizar un proyecto de trabajo en función de unos objetivos que le vienen dados. Dicho en otras palabras, el intérprete de las imágenes tiene que tomar una serie de decisiones para cumplir unos requisitos emanados de la institución a la que debe presentar ese trabajo, la Administración u otra empresa, habitualmente en forma de pliego de condiciones del proyecto. En esos casos, este epígrafe resultará superfluo, y el lector puede moverse directamente a los siguientes, ya que poco podrá decidir sobre los objetivos del trabajo. En cambio, si se trata de un proyecto de investigación, en donde comúnmente es el propio intérprete el que plantea las metas a alcanzar, la lectura de estos párrafos puede ayudar a diseñar esos objetivos con mayor eficacia.

Como criterio general, conviene subrayar la importancia de que los objetivos de un proyecto se adapten a las posibilidades de los datos que se van a emplear en su desarrollo. El comentario puede parecer obvio, pero en la práctica no lo es tanto, ya que en muchas ocasiones se han planteado proyectos de teledetección poco rea-

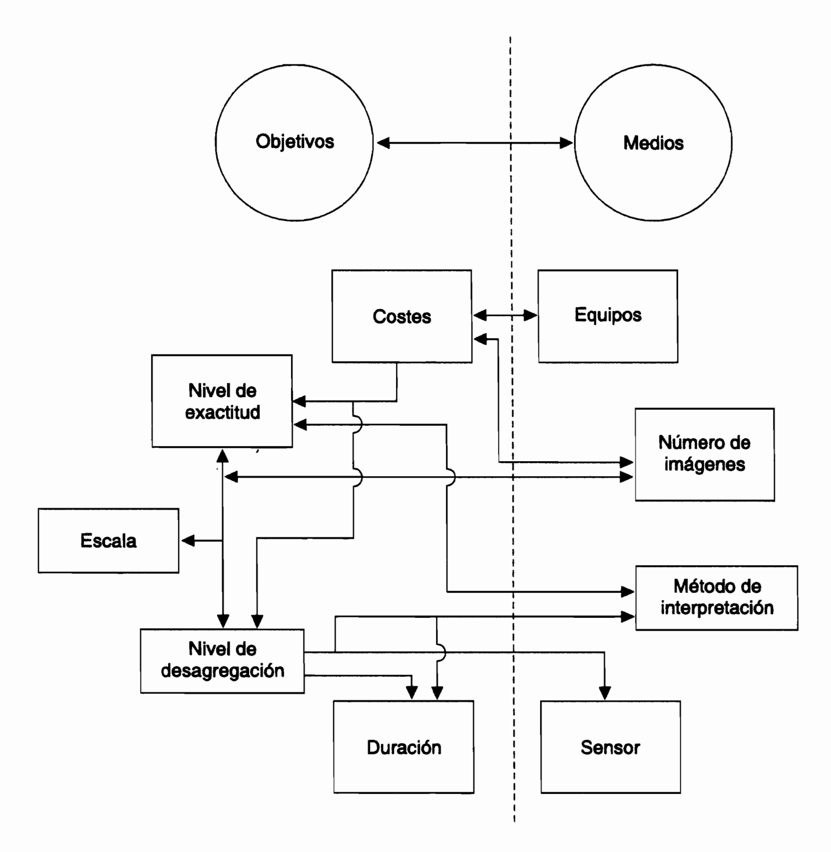


FIG. 4.3. *La interpretación de imágenes en teledetección implica tomar una serie de decisiones que optimicen los objetivos perseguidos en función de los medios disponibles.*

listas, que no contemplaban las limitaciones inherentes a la técnica o a los sensores específicos que había disponibles en esos momentos. Como antes hemos comentado, algunos usuarios, llevados de un cierto desconocimiento o de un interés comercial poco prudente, han podido vender falsas expectativas respecto a la calidad de la información que ofrecen los sensores remotos, lo que implica una rémora para el desarrollo futuro de esta técnica. Cuando se plantea un proyecto de investigación, su nombre ya lo indica, intentamos validar nuevos métodos, datos o aplicaciones, con una cierta posibilidad de que no conduzcan a avances significativos: a veces se olvida que negar la hipótesis de partida es tan científico como ratificarla, siempre que los métodos y la validación de resultados sean rigurosos. En consecuencia, en estos casos, puede aceptarse un margen de incertidumbre y fracaso, pero no sería prudente ofrecer un proyecto de investigación como si se tratara de una aplicación ya consolidada, obviando los aspectos no resueltos, que van a condicionar notablemente los resultados.

La confusión entre aplicaciones operativas y experimentales puede marginar el empleo de la teledetección en instituciones que de otro modo estarían abiertas a emplear esta técnica. En consecuencia, nos parece muy importante que se planteen

unos objetivos realistas, bien fundados sobre bibliografía de referencia, y adaptados a la resolución espacial, espectral y temporal de los sensores que tendremos disponibles. La definición de objetivos hace referencia no sólo al propósito genérico del trabajo (p. ej., realizar un inventario de cultivos), sino también a sus especificaciones: a qué escala, con qué nivel de desagregación, con qué precisión, en cuánto tiempo, a qué coste...etc.

3.2. Escala y leyenda de trabajo

La escala y el nivel de desagregación están íntimamente relacionados. Como es lógico, las escalas grandes requerirán leyendas mucho más detalladas que las escalas pequeñas, donde no tendrá sentido intentar distinguir un número elevado de clases: la necesaria generalización de líneas en mapas de pequeña escala exige también una generalización de las categorías cartografiadas.

Por ejemplo, la escala del trabajo condiciona también la unidad más pequeña de información que se debe incluir en un mapa temático, que suele denominarse mínima unidad cartografiable (MUC). Varios autores recomiendan que la MUC no sea inferior a 4 mm^2, medidos a escala del mapa (Anderson *et al.*, 1976; Campbell, 1996), por lo que la escala nos apunta directamente al nivel de resolución espacial más adecuado para un determinado estudio (Robin, 1998, fig. 4.4). No tendría sentido realizar una cartografía a escala 1:50.000 utilizando el sensor AVHRR del NOAA, pues la MUC sería de, aproximadamente, 2 × 2 cm (1 km^2 a esa escala). De igual forma, no sería muy razonable abordar un estudio de pequeña escala (p. ej, 1:1.000.000) a partir del sensor Landsat-TM, pues habrían de generalizarse luego los resultados, lo que no justificaría la inversión inicial. De acuerdo con la Asociación Cartográfica Internacional, las escalas límite más idóneas para algunos sensores son:

NOAA - AVHRR ,	1:2.000.000
Terra - MODIS (1 km),	1:1.000.000
Terra - MODIS (500 m),	1:500.000
Landsat - MSS,	1:200.000
Landsat - TM,	1:100.000
Spot - HRV (Pan),	1:50.000
Spot - HRG (XS-P),	1:25.000
Ikonos (XS),	1:25.000
Ikonos (P),	1:10.000

No conviene confundir la MUC con el tamaño del mínimo objeto que puede observarse en la imagen. Obviamente, aquélla tiene que ser mucho más grande que éste, de lo contrario el riesgo de error aumenta considerablemente. En este sentido conviene distinguir entre los conceptos de identificación y detección, bastante empleados en análisis visual de imágenes (entre otros, puede verse Robin, 1998). La identificación hace referencia al reconocimiento de las características de un determinado objeto, que nos permite caracterizarlo en sus formas y superficies reales, mien-

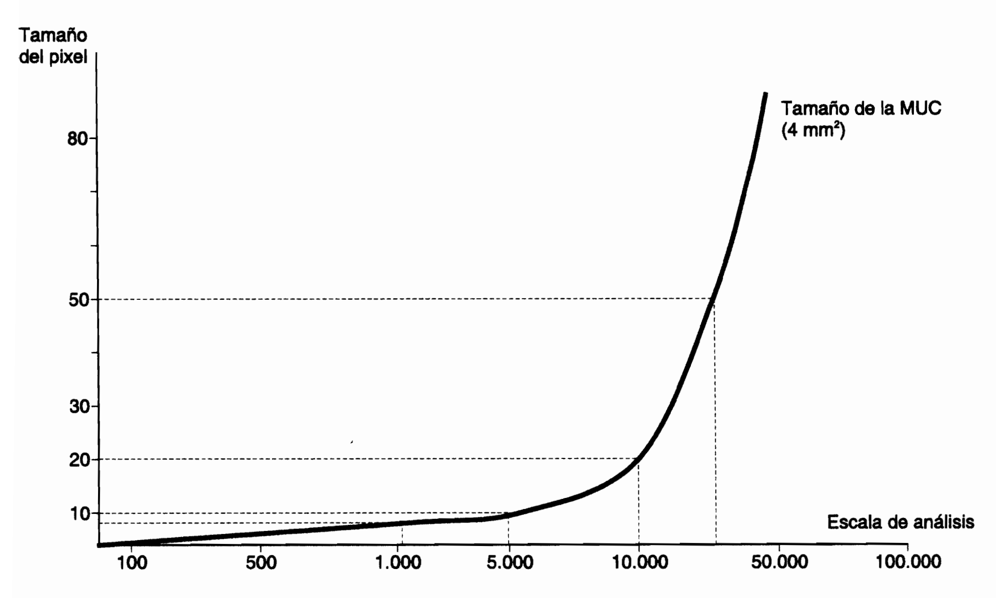


FIG. 4.4. *Relaciones entre resolución y tamaño de la MUC (adaptado de Robin, 1998).*

tras que la detección sólo implica determinar su existencia. Lógicamente, la primera tarea requiere mucho más resolución espacial que la segunda, pues sólo será reconocible algo con un tamaño muy superior al del píxel (al menos 5 veces superior, según la mayor parte de los autores), mientras que para ser detectado puede ser incluso inferior al tamaño del píxel. Por ejemplo, puede determinarse la presencia de un río en una imagen, incluso si es de anchura inferior a la resolución espacial, gracias al fuerte contraste en la absorción del agua, que hará bajar la reflectividad de los píxeles por los que discurre. Sabremos que está allí, pero no podremos medir su anchura o forma, que sólo será perceptible a partir de imágenes más precisas (fig. 4.5). En consecuencia, si lo que se pretende es interpretar rasgos específicos de la imagen, su tamaño medio marcará el nivel mínimo de resolución que puede admitirse en una imagen. Por ejemplo, no parece adecuado adquirir imágenes de un sensor de resolución media para análisis urbano, donde será inevitable disponer de alta resolución espacial.

Con la generalización del empleo de imágenes de satélite en distintas aplicaciones cartográficas va siendo cada vez más frecuente que distintos proyectos temáticos se basen en esta información. Esto nos permite encontrar diversos ejemplos de proyectos cartográficos a distintas escalas realizados a partir de teledetección. Entre ellos, podemos citar desde escalas globales, que cubren todo el planeta, normalmente con resoluciones entre 1 × 1 km y 0,5 × 0,5 grados, y se basan en imágenes AVHRR, Vegetation o MODIS (Ahern *et al.*, 2001; Chuvieco, 2008*a*; DeFries y Townshend, 1994), hasta inventarios regionales, con escalas próximas a 1:100.000, que cubren países o continentes, basados en imágenes Landsat-TM o SPOT-HRV (*European Commission*, 1993). El trabajo de Martínez (1996) analiza diversos proyectos cartográficos a escala global, nacional y regional llevados a cabo con imágenes de satélite en distintos ámbitos geográficos.

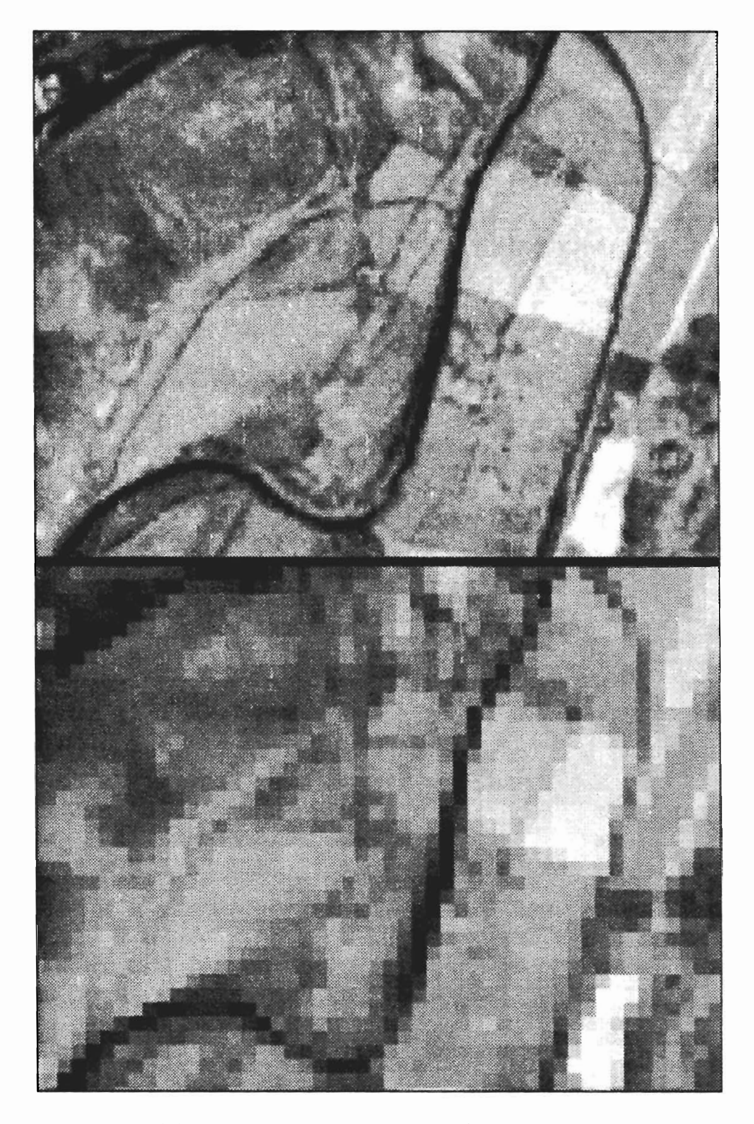


FIG. 4.5. *Dos imágenes del río Henares, en las proximidades de Alcalá, a 15 m de resolución en la parte superior, y a 180 m en la inferior. En la primera puede identificarse el río, en la segunda sólo detectarse.*

En lo que se refiere a la leyenda de la cartografía temática, conviene indicar que no sólo está en función de la escala, sino también de la complejidad del territorio. Como consecuencia, ha sido práctica habitual en algunos inventarios (como, por ejemplo, en la cartografía de ocupación del suelo) emplear una leyenda particular para cada zona de estudio, bien adaptada a las necesidades locales, pero con escasa validez para otros ámbitos. Por ejemplo, hace algunos años tuvimos ocasión de analizar una muestra de 28 trabajos relacionados con la cartografía de ocupación del suelo a partir de teledetección, notando que ninguno presentaba criterios comunes

para el establecimiento de la leyenda (Chuvieco, 1985*a*). Las clases más repetidas eran agua —la más fácil de discriminar a partir de sensores espaciales—, área urbanizada, cultivada y forestal, aunque en estas últimas se realizaban múltiples divisiones, según los objetivos específicos del inventario. Esta falta de criterios comunes dificulta la generalización de resultados a otros espacios, e invalida cualquier intento de cartografía sistemática del territorio.

En caso de que la leyenda no sea un requisito previo al trabajo (esto es, que no estén fijadas *a priori* por el cliente las categorías que quieren discriminarse), el intérprete debería cuidar mucho este aspecto, de tal forma que las clases establecidas tengan coherencia entre sí, y con las herramientas que vamos a utilizar en el análisis. En este sentido es especialmente importante que la leyenda no incluya clases que puedan solaparse entre sí, y que recoja toda la variación posible que haya en el área de estudio. En definitiva, que las clases sean mutuamente excluyentes y exhaustivas, propiedades obvias, pero no por ello universalmente respetadas, de cualquier tipología de clasificación. Es frecuente observar que se mezclan criterios a la hora de definir las clases de una determinada leyenda, lo que implicará un cierto margen de aleatoriedad en el proceso. Por ejemplo, la clase matorral en ladera, implica mezclar dos temas distintos: cobertura y emplazamiento, y no resulta una categorización exhaustiva, ya que no podríamos asignar el matorral que se presente en otros ámbitos geomorfológicos. Las clases pinar de repoblación y pinar sobre calizas no son excluyentes, pues puede haber lógicamente pinar de repoblación situado sobre calizas.

De cara a establecer leyendas más robustas, se han planteado diversas propuestas de clasificación, que incorporan un carácter jerárquico, eso permite adaptar distintos niveles de detalle (desagregación de clases) en función de la calidad de los datos disponibles.

Un ejemplo de este tipo de leyendas es la diseñada por el *U.S. Geological Survey* en 1976, específicamente concebida para el empleo de sensores remotos (Anderson *et al.*, 1976). Se trataba de una leyenda de uso y ocupación del suelo, organizada en cuatro niveles jerárquicos, cada uno de los cuales se pretendía obtener a partir de diversos medios de teledetección: imágenes de satélite para el nivel más general, y fotografía aérea de gran escala, en combinación con el trabajo de campo, para las clases más detalladas. Esta clasificación resultaba flexible, podía aplicarse a espacios muy contrastados, y garantizaba la integración entre campos afines de inventario medioambiental. El principal problema que presentaba, a nuestro juicio, era la inclusión en el mismo esquema de clases de uso y de ocupación del suelo,[1] lo que origina ambigüedad en el proceso de clasificación. Por ejemplo, un mismo objeto o grupo de ellos podrían asignarse a varias categorías de acuerdo a su consideración como uso u ocupación: canteras (uso) y roquedo desnudo (ocupación), o dehesa (uso) y pastizal arbolado (ocupación). Como es lógico, los sistemas de teledetección sólo permiten realizar cartografía de la ocupación del suelo, ya que la señal detectada por el sensor

1. Siguiendo la terminología anglosajona, distinguimos entre uso y ocupación del suelo (*land use* y *land cover*, respectivamente), según nos refiramos a la actividad humana sobre el territorio o a las cubiertas que aparecen sobre él (E. Chuvieco [1985*a*]: «Aportaciones de la teledetección espacial a la cartografía de ocupación del suelo», *Anales de Geografía de la Universidad Complutense*, 5: 29-48).

TABLA 4.1. *Clasificación propuesta para el proyecto de ocupación del suelo de Europa (CORINE-Land Cover)**

1. *Superficies edificadas e infraestructuras:*
   1.1. Zonas urbanas.
   1.2. Zonas industriales, comerciales y de transporte.
   1.3. Zonas de extracción minera, vertederos y de construcción.
   1.4. Zonas verdes y espacios de recreo.
2. *Zonas agrícolas:*
   2.1. Tierras de labor anual.
   2.2. Cultivos permanentes.
   2.3. Praderas.
   2.4. Zonas agrícolas heterogéneas.
3. *Zonas forestales, con vegetación natural y espacios abiertos:*
   3.1. Bosques.
   3.2. Espacios de vegetación arbustiva y/o herbácea.
   3.3. Espacios abiertos con poca o nula vegetación.
4. *Zonas húmedas:*
   4.1. Humedales continentales.
   4.2. Humedales marítimos.
5. *Superficies de agua:*
   5.1. Aguas continentales.
   5.2. Aguas marinas.

* Sólo se recogen los dos primeras niveles de la clasificación. En la adaptación española de la leyenda comunitaria se llega, en algunas cubiertas, hasta los cinco niveles.

corresponde a los objetos que aparecen en la superficie terrestre, y no necesariamente al uso al que se destinan. El uso podría ser deducido por el intérprete en algunos casos (por ejemplo, a partir de una cubierta de cultivos, se infiere fácilmente un uso agrícola), pero no en otros (a partir de una cubierta de matorral no puede deducirse si el uso es ganadero o cinegético).

Pese a este problema, el trabajo de Anderson y colaboradores ha sido enormemente fructífero, y base para otros intentos similares. Este es el caso de la leyenda diseñada para el programa CORINE-Land Cover (tabla 4.1), realizada específicamente para trabajar con imágenes de satélite. Este proyecto forma parte de las bases de datos que se han generado para la Agencia Europea de Medioambiente, y pretendía inventariar la ocupación del suelo de los países miembros a escala 1:100.000 a partir de interpretación visual (auxiliada con análisis digital) de imágenes de satélite. El proyecto, al que más tarde se unieron los países de la antigua Europa oriental y algunos del norte de África, puede calificarse como una de las primeras aplicaciones operativas de la teledetección espacial (descontando, naturalmente, las meteorológicas), ya que está concebido para generar un inventario sistemático de la cobertura del suelo de un amplio territorio (*European Commision*, 1993; López Vizoso, 1989; Moreira y Fernández-Palacios, 1995; Mounsey, 1991). La leyenda incluye también un enfoque jerárquico, de tal manera que cada país pueda enriquecer un esquema común de partida en función de sus propias necesidades, a la vez que se mantiene una coherencia entre países para asegurar que los resultados sean comparables. Tras el primer inventario CORINE del territorio europeo en 1990, se completó otro

referido al año 2000, y para nuestro país está en fase de desarrollo la actualización para el año 2005. Frente a la exclusiva interpretación visual de la primera cobertura en este segundo inventario del proyecto CORINE Land Cover se han empleado algunas herramientas de interpretación digital (Smits y Annoni, 1999).

En la última actualización del proyecto se ha definido una leyenda mucho más amplia, enmarcada en el proyecto SIOSE (Sistema de Información sobre Ocupación del Suelo de España), que permite contemplar diversos parámetros para cada polígono de cobertura, facilitando así una descripción mucho más detallada de las características del territorio, así como de los cambios que experimenta (Observatorio de la Sostenibilidad, 2006). En esta línea también la FAO ha propuesto una definición de categorías de cobertura basada en parámetros, que permite aplicar los productos resultantes a aplicaciones muy variadas (Di Gregorio y Jansen, 2000).

Otros intentos similares a los del programa Corine-Land Cover se han planteado en otros países, aunque tal vez no con la trascendencia internacional de este proyecto. Por el carácter global, basta finalmente con citar el mapa de cobertura del suelo de todo el planeta realizado por uno de los grupos de trabajo del programa IGBP *(International Geosphere Biosphere Program)* a partir de imágenes NOAA-AVHRR (DeFries y Townshend, 1994; Loveland *et al.*, 2000). Más recientes son el proyecto GLC 2000, realizado por al Centro Común de Investigación de Ispra sobre datos SPOT-Vegetation del año 2000 (Bartholome y Belward, 2005), o el que elabora la Universidad de Bostón en el marco del programa MODIS (Friedl *et al.*, 2002), que también incluye cambios en la cobertura del suelo.

Sea una u otra la lista de categorías finalmente empleada, conviene recordar que el nivel de detalle que ofrece la leyenda se relaciona estrechamente con el riesgo de error, por cuanto es altamente probable que cualquier subdivisión implique separar categorías muy similares espectralmente. Caso de que esa ulterior división no sea abordable a partir de las imágenes o del método de interpretación propuesto, deberá el usuario ajustar alguno de los dos parámetros: bien hacia una leyenda más generalista, bien hacia imágenes o métodos de tratamiento más refinados.

3.3. Selección de los materiales

Una vez establecida la leyenda y escala de trabajo, puede abordarse la elección del material que constituirá la base del estudio. A este respecto, conviene considerar varios elementos: tipo de sensor, fecha de adquisición, soporte de las imágenes y material auxiliar.

3.3.1. *Tipo de sensor*

Como ya se ha indicado, el tipo de sensor más conveniente depende de los objetivos y el nivel de precisión requerido en el proyecto. Lógicamente, los inventarios globales habrán de partir de sensores de baja resolución espacial (tipo NOAA-AVHRR o Meteosat), mientras que los de mayor escala se basarán en sensores que ofrecen una resolución espacial más detallada (IRS o IKONOS).

No obstante, en otros casos la resolución espacial resulta secundaria frente a la

temporal o espectral. Por ejemplo, si el fenómeno estudiado es muy dinámico, como sería el caso de la detección de incendios forestales o la predicción de cosechas, convendrá acudir a sensores de alta resolución temporal (como MODIS), aun sacrificando precisión espacial. En otras ocasiones, la dimensión espectral será dominante, por lo que convendrá acudir a sensores que ofrezcan información en aquellas bandas del espectro donde se manifieste con mayor claridad el fenómeno de interés. Un buen ejemplo de esta idea sería la exploración minera, que se enriquece bastante con el acceso a sensores hiperespectrales (Kruse *et al.*, 1993*b*). En definitiva, la resolución espacial es un elemento muy destacado para seleccionar el sensor más conveniente en cada caso, pero no debe ser el único a considerar (ver 3.2).

3.3.2. *Fecha de adquisición*

La fecha más conveniente de la imagen depende estrechamente del tipo de fenómeno que quiera estudiarse. Lógicamente, el momento más idóneo de adquisición será aquel en que mejor se discrimine ese fenómeno frente a otros de similar comportamiento espectral. Por ejemplo, si se pretende abordar un análisis geomorfológico, será conveniente utilizar una fecha invernal, al ser mayor el efecto de sombras y, por tanto, más clara la detección de rasgos del relieve. Por el contrario, el inventario de algunos cultivos de regadío sólo puede realizarse en los meses de verano, julio y agosto en el hemisferio norte, cuando se encuentran en el suelo (naturalmente, otros cultivos de regadío, con otros calendarios fenológicos, requerirán otras fechas más apropiadas, caso del viñedo, que convendrá mejor observarlo a inicios del otoño. En ocasiones, resultará necesario acudir a varias fechas para llevar a cabo una buena discriminación: por ejemplo, para seguir el ritmo de crecimiento de un determinado cultivo, o para estudiar los cambios entre dos momentos críticos (7.3.3). En estas situaciones, conviene construir un calendario fenológico de esa cubierta —y de las que ofrezcan un parecido comportamiento espectral—, con objeto de seleccionar las fechas en donde su comportamiento sea más específico del resto.

Una vez seleccionada una o varias fechas idóneas para la adquisición, conviene tener en cuenta que no todos los sensores adquieren las imágenes sistemáticamente. Algunos sistemas sólo adquieren información bajo pedido, lo que dificulta ciertamente el análisis histórico, sobre todo cuando se pretenda analizar el impacto de un determinado fenómeno (por ejemplo, una inundación) comparando con la situación precedente. Dentro de los sensores que requieren un pedido previo, también puede distinguirse entre los que sólo pueden adquirir imágenes en la vertical y los que permiten adquisiciones no verticales. En el primer caso, las imágenes se adquieren con el intervalo temporal de las órbitas estándar, mientras en el segundo el satélite puede programarse para obtener datos de zonas de interés en las fechas que se requieran. Esta utilidad es bastante empleada en agricultura de precisión pues la discriminación de ciertos cultivos está constreñida a un período bastante corto, donde la frecuencia estándar de observación puede no ser suficiente. La mayor parte de los sensores de media y alta resolución (SPOT, IKONOS, Quickbird) tienen la capacidad de programar las adquisiciones, variando el ángulo de visión de la cámara para tomar imágenes de una zona aunque el satélite no pase por la vertical. Los costes

son más altos, lógicamente, pero esto garantiza cumplir unos determinados plazos. La alternativa sería la teledetección aeroportada, con la que resulta más sencillo planificar la adquisición para días determinados.

Cuando en estos trabajos de cartografía de la cubierta vegetal se disponga de un presupuesto escaso, puede ser preciso seleccionar una sola fecha que maximice la separación entre todas las cubiertas. En ese caso, la elección más conveniente será una imagen adquirida en el verano, pues en ese momento es máxima la radiancia media percibida por el sensor, como consecuencia del mayor ángulo de elevación solar. Además, en el caso del clima mediterráneo, la estación estival coincide con la época de menor nubosidad y precipitación, lo que facilita la selección de imágenes de este período.

3.3.3. *Soporte de las imágenes*

El soporte sobre el que puede realizarse la interpretación depende del tipo de tratamiento que se aplique. En caso de que se opte por el análisis visual, se requiere resolver tres aspectos: (1) soporte material de la imagen, (2) escala, y (3) número de bandas y combinación de bandas seleccionadas.

En lo que se refiere al primer aspecto, hasta hace muy pocos años las entidades distribuidoras de imágenes ofrecían tres opciones. Las imágenes podían pedirse en película negativo, en película positivo o en papel. Todavía estos formatos pueden encontrarse para imágenes históricas o para misiones fotográficas, como algunas del Space Shuttle. Actualmente, casi todas las empresas que comercializan imágenes de satélite lo hacen exclusivamente en formato digital: queda, por tanto, al usuario la labor de convertir esos valores numéricos en tonos de gris o color si lo que pretende es realizar una interpretación visual de la imagen.

Para los documentos más antiguos, baste indicar que los negativos permiten ampliaciones muy versátiles, ajustándose a la escala deseada, pero la calidad de la copia que se obtenga luego en papel es inferior a la adquirida directamente en este soporte. El film positivo es muy útil para reproducción fotográfica e impresión de la imagen, especialmente cuando se trata de composiciones coloreadas de 3 bandas. Por último, los productos que facilitaban las agencias distribuidoras en papel garantizaban una interpretación directa de alta calidad, pero resultaba rígida la escala y no admitía copias sucesivas. Cuando se trata de composiciones en color, a partir de los negativos de cada banda podían obtenerse tantas combinaciones como requiere el intérprete, mientras el film positivo o papel debía solicitarse ya con una determinada combinación de bandas. Naturalmente, ahora pueden generarse productos en papel a partir de la información digital, mucho mejor adaptados a las necesidades del intérprete, gracias a la creciente disponibilidad de trazadores gráficos en color de amplio formato. Actualmente, cada vez es más frecuente realizar la interpretación visual sobre el propio monitor de visualización, digitizando directamente los polígonos identificados por el intérprete. En ese caso, el soporte de la imagen será la consola, la escala será variable, en función del nivel de magnificación empleado, y la combinación de bandas puede modificarse fácilmente por el intérprete.

En cuanto al soporte de la información digital, hace algunos años lo más común eran las cintas compatibles con ordenador (CCT), que eran el único medio via-

ble de almacenar un volumen importante de datos. Actualmente las tecnologías magnéticas han dejado paso a las ópticas, inicialmente el CD-ROM y más recientemente el DVD (*Digital Video Disk*), que son los medios más comunes para realizar copias de seguridad, por su bajo coste y fácil accesibilidad.

Para la distribución de imágenes, en los últimos años se está generalizando el uso de internet, ya sea a través de sistemas de protocolos de transferencia de archivos (ftp) o mediante servidores de imágenes web. Esto facilita mucho la rapidez en el acceso a la información, pues se ahorran los tiempos y gastos de correo.

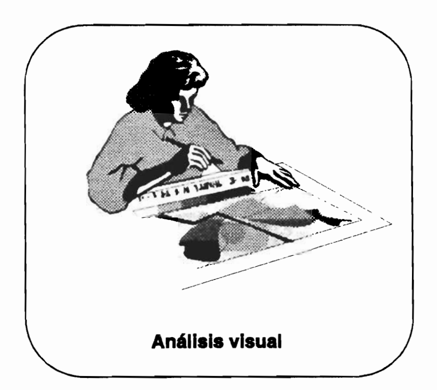
3.4. METODOLOGÍA DE INTERPRETACIÓN: ¿ANÁLISIS VISUAL O DIGITAL?

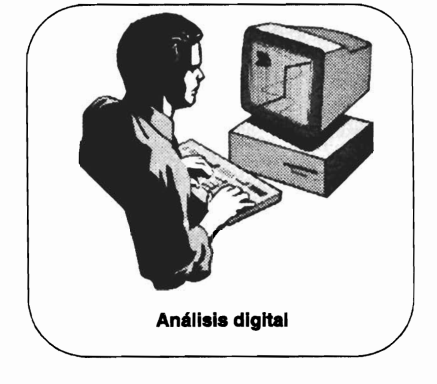
Como es bien sabido, las imágenes de teledetección son en su mayor parte adquiridas en formato digital. Por tanto, el tratamiento digital resulta la opción de análisis más inmediata. Ahora bien, los valores digitales de una imagen también pueden convertirse a intensidades de brillo o color, con lo que pueden generarse productos cuasifotográficos, susceptibles de interpretación visual.

En consecuencia, las imágenes pueden interpretarse digital o visualmente. Cabe preguntarse cuál de los dos resulta más idóneo para explotar adecuadamente el flujo de datos que la teledetección espacial ofrece. La respuesta no resulta sencilla. Simplificando un poco las cosas, pueden señalarse varios aspectos que conviene tener en cuenta antes de tomar una decisión en uno u otro sentido: 1) medios económicos y humanos disponibles, 2) rapidez y precisión exigida, 3) tipo y continuidad de las tareas, 4) homogeneidad de la superficie analizada (fig. 4.6).

En cuanto a los costes, ya hemos indicado que actualmente casi todas las imágenes se distribuyen en formato digital, por lo que la interpretación visual requeriría de algún sistema informático para acceder a esos datos, visualizándolos en un monitor o imprimiéndolos en papel. En este sentido los costes serían similares al tratamiento digital, si bien la visualización puede hacerse con *software* menos costoso (programas de retoque fotográfico, incluso de dominio público). La excepción sería utilizar alguna de las series cartográficas con orto-imágenes estándar (Martínez Vega, 1997), que pueden servir para un análisis visual, lógicamente limitada a la fecha de adquisición de la serie. Ahora bien, la inversión inicial hace referencia también al entrenamiento previo del intérprete. El análisis visual emplea claves de identificación similares a la foto-interpretación clásica (tono, textura, tamaño, localización, forma, etc.), por lo que no requiere un entrenamiento previo muy especializado, si bien, como es lógico, precisa de una notable agudeza visual y mental, así como la debida experiencia, para obtener resultados brillantes. El tratamiento digital, por su parte, requiere una buena base estadística, conocimiento de sistemas informáticos y lenguajes de programación. Aunque en los últimos años se ha avanzado mucho en este sentido, estos componentes no suelen formar parte de los currículos vigentes en las ciencias de la Tierra, por lo que puede resultar complejo el acceso al tratamiento digital para personas provenientes de esos campos de aplicación, aunque conviene considerar que esa base estadística e informática es sólo un medio para mejorar la interpretación, y no un fin en si mismo.

En cuanto a la exactitud, el hecho de trabajar directamente con los datos digi-





Análisis visual	Análisis digital
Inversión inicial escasa	Inversión elevada
Costes lineales	Costes se reducen con la superficie
Requiere conversión digital analógica	Permite trabajo con información original
No precisa alta especialización	Precisa alta especialización
Buena precisión en clases heterogéneas	Baja precisión en clases heterogéneas
Restitución compleja	Corrección geométrica sencilla y rápida
Inventario tedioso e inexacto	Inventario inmediato
Requiere digitalización para conectarse a un SIG	Conexión directa (formato raster) o vectorización (formato vectorial)

FIG. 4.6. *Ventajas e inconvenientes del análisis visual frente al digital en la interpretación de imágenes.*

tales supondría que la interpretación asistida por ordenador sería más precisa que la visual. Sin embargo, esto no siempre es así cuando nos referimos a categorías que pueden ser una mezcla de varias clases espectrales. Varios autores han comprobado la complejidad de clasificar digitalmente cubiertas que ofrecen una gran heterogeneidad espacial. El caso de las áreas urbanas es el más claro a este respecto (Atkinson *et al.*, 1985; Toll, 1984). Se trata de zonas en donde se mezclan tejados, aceras, asfalto, jardines y espacios abiertos o deportivos. Esta complejidad puede identificarse visualmente gracias a criterios muy difícilmente traducibles a la clasificación digital: localización, textura, tamaño, formas, etc., por lo que la interpretación visual ofrecerá, en este caso, mayor exactitud que la digital. Aunque en los últimos años se ha intentado reforzar los criterios de clasificación digital mediante el empleo del contexto espacial y los clasificadores basados en objetos (Ferro y Warner, 2002; Gitas *et al.*, 2004; Schiewe *et al.*, 2001; Zhang *et al.*, 2005), todavía resulta complejo clasificar digitalmente categorías que están formadas por diversos atributos espectrales o incluso temáticos (Arroyo *et al.*, 2006). En otras categorías, la relación resulta contraria, ya que el ojo humano no es capaz de detectar variaciones tonales que sí son diferenciables numéricamente (humedales, transiciones de vegetación, distintos cultivos...).

Otro elemento a tener en cuenta para elegir la interpretación visual o digital se refiere al tipo y continuidad de las tareas requeridas en el proyecto. Si el estudio sólo precisa un croquis de interpretación y no una plasmación cartográfica, la interpreta-

ción visual no ofrece inconvenientes. Ahora bien, si se pretende obtener un mapa deben transferirse todas las líneas que definen las distintas cubiertas a la cartografía base, lo cual resulta muy tedioso y poco preciso, incluso con restituidores analógicos. El tratamiento digital, por el contrario, permite realizar este proceso con gran rapidez y, salvo terrenos muy accidentados, con elevada precisión, gracias a las técnicas de corrección geométrica de la imagen (6.6.3). Lógicamente, estas correcciones digitales pueden aplicarse como paso previo a la interpretación visual, y de hecho la mayor parte de los organismos distribuidores de imágenes incluyen la opción de solicitar las imágenes ya georreferenciadas, si bien son más costosas que las originales y, en ocasiones, no ofrecen elevada precisión (dependerá si esa corrección se basa sólo en modelos orbitales o si se enriquece con puntos de control).

Otras operaciones que resultan muy beneficiadas con el tratamiento digital son el inventario de resultados y su integración con otras variables geográficas. El inventario resulta muy tedioso en interpretación visual, pues es necesario planimetrar todas las superficies incluidas en cada tipo de cubierta. En el caso del tratamiento digital basta realizar un cálculo de frecuencias —esto es, del número de píxeles incluidos en cada clase—, para conocer la superficie ocupada por cada una de ellas, por cuanto sabemos la equivalencia superficial de cada píxel. Naturalmente, en caso de que se opte por la interpretación visual y digitización simultánea en pantalla, las imágenes ya estarán georreferenciadas, por lo que el inventario se obtiene también casi de modo inmediato.

Respecto a la posibilidad de combinar los resultados del análisis con otro tipo de variables territoriales: suelos, hidrografía o pendientes, la integración manual convencional resultaba muy compleja (técnica de superponibles), mientras que la asistida por ordenador supone un proceso relativamente sencillo en el marco de los Sistemas de Información Geográfica (SIG, cap. 9). La entrada de información en estos sistemas requiere una previa digitización para el caso del análisis visual, mientras que resulta un proceso bastante inmediato en tratamiento digital —especialmente si el SIG almacena la información en formato ráster— puesto que las imágenes ya se encuentran en soporte numérico. Como antes indicamos, si la interpretación visual se realiza sobre pantalla, la digitización es inmediata y, por tanto, su integración en un SIG y el acceso a las funciones de análisis que estos sistemas proporcionan.

En resumen, y siguiendo nuestra opinión particular, ambos métodos de trabajo se complementan, y pueden emplearse integradamente. El tratamiento digital permite realizar operaciones complejas, muy costosas o inaccesibles al análisis visual. Garantiza una clasificación más rápida de la zona de estudio, manteniendo una coherencia en la asignación de áreas vecinas a dos categorías, a la vez que permite generar la distribución espacial de variables biofísicas (temperatura, clorofila en el agua, etc.), y simplifica la determinación de cambios temporales. Por su parte, el análisis visual es una buena alternativa para actualizar cartografía existente, identificar clases heterogéneas o realizar inventarios a escalas medias o de semidetalle. Apoya a la clasificación digital, aislando sectores de potencial confusión sobre la imagen, o estratificando algunos sectores de la imagen para aplicarles tratamientos específicos. En este marco, podríamos aprovechar la potencia de análisis de la interpretación visual (incluyendo criterios de contexto, textura, formas complejos que puede emplear un intérprete humano), así como la flexibilidad y potencia del tratamiento digital (geo-

rreferenciando la imagen, mejorando su aspecto visual, digitizando información en pantalla, etc.). En definitiva, podemos actualmente hablar de una fotointerpretación asistida por ordenador, que elimina diversas fases de la interpretación visual clásica (restitución, inventario). A la vez, esa interacción visual con el intérprete permitirá resolver algunos problemas del tratamiento digital, que encuentra notables dificultades para automatizar la interpretación de ciertos rasgos de la imagen (algunas nubes, áreas urbanas...), que son bastante obvios al análisis visual.

4. Fases en la interpretación

Las aplicaciones de la teledetección espacial son muy numerosas, por lo que resulta complejo establecer un marco general, que pueda ser válido para todas ellas. No obstante, y aun a riesgo de caer en la simplicidad, puede ser conveniente introducir algunas ideas sobre el proceso de trabajo con este tipo de imágenes. No será difícil que cada usuario pueda ajustar este esquema a sus propios intereses.

El proceso propuesto contempla las siguientes fases (fig. 4.7):

1. Definición expresa y concreta de objetivos, señalando las limitaciones que se presentan, ya sean derivadas del área de estudio (complejidad), ya de los requisitos del trabajo (duración del proyecto, coste máximo, categorías temáticas a discriminar, etc.) o de los medios disponibles.
2. Revisión bibliográfica y propuesta de método. En función de la literatura consultada sobre el tema, podrán plantearse las alternativas metodológicas más razonables. Un estudio bibliográfico resulta vital para orientar el proceso de análisis, optimizando las decisiones futuras.
3. Trabajos de campo preparatorios y acopio de información auxiliar. En este primer contacto, los trabajos de campo permiten familiarizar al intérprete con la zona objeto de estudio, estudiar sus rasgos medioambientales y humanos. Si se trata de una aplicación relacionada con la cubierta vegetal, resulta conveniente elaborar un calendario fenológico de las especies de interés con objeto de seleccionar la fecha o fechas más apropiadas para adquirir la imagen. En esta fase pueden incluirse las medidas a realizar con radiómetros de campo —que permiten caracterizar espectralmente la cubierta y seleccionar el sensor y las bandas más apropiadas para discriminarla—, así como el acopio del material auxiliar necesario para la posterior interpretación de la imagen (fig. 4.8). Las campañas de medición en terreno resultan claves para poder establecer posteriormente relaciones cuantitativas con los datos de la imagen.
4. Selección de la información de partida: sensor y fecha (o fechas) más conveniente, número de imágenes, soporte, etc.
5. En caso de que la leyenda no sea un requisito del proyecto (esto es, que ya estén marcadas las categorías que necesitan discriminarse), el usuario deberá plantear una leyenda adecuada de trabajo, basada sobre las características de la zona y las posibilidades que brinda el sensor seleccionado.
6. Trabajos de campo de calibración. Una vez adquiridas las imágenes, esta segunda fase de campo sirve para familiarizar al intérprete con la imagen, caracte-

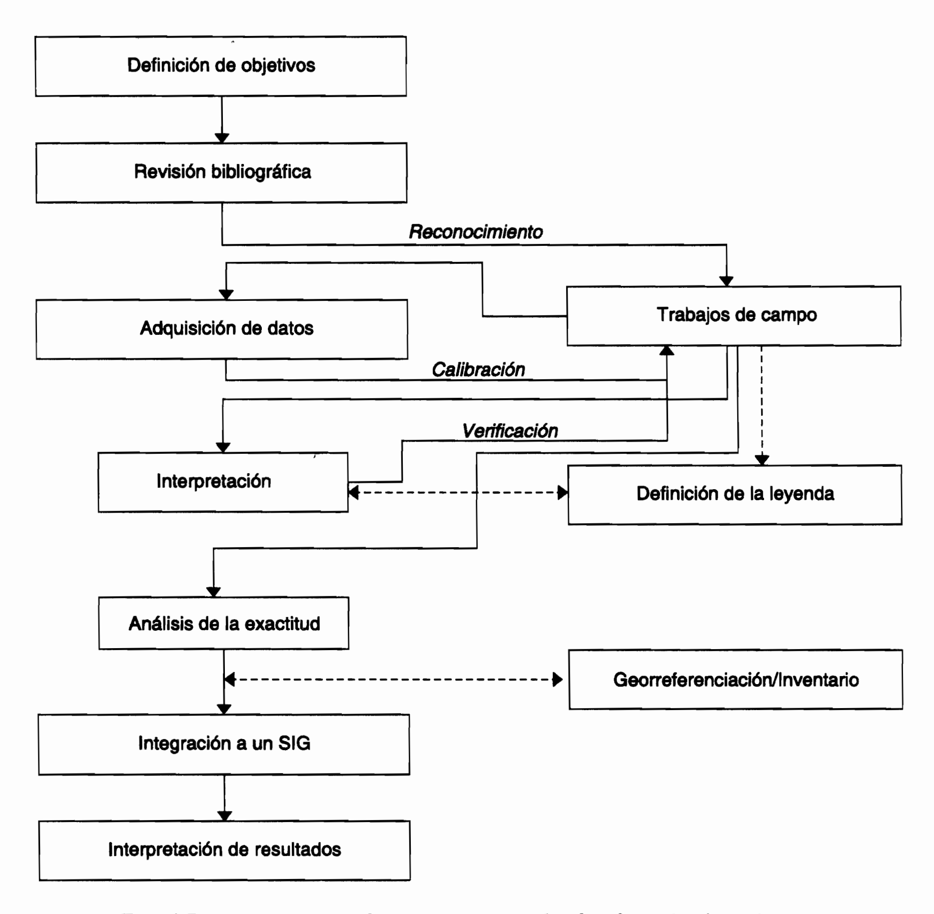


FIG. 4.7. *Fases que incluye un proyecto de clasificación de imágenes.*

rizando sobre ella la variación de las distintas clases señaladas en la fase anterior. Esta fase debería realizarse simultáneamente a la adquisición de la imagen, con objeto de evitar cualquier ruido posterior en el análisis que pueda deberse a variación de las condiciones entre terreno e imagen. Caso de que el trabajo pretenda generar una variable cuantitativa, aquí deberíamos realizar las medidas de campo de esa variable para calibrar y luego validar el modelo (caso de que sea empírico), o únicamente validarlo (caso de que sea teórico).

7. Interpretación de estas cubiertas, ya sea a través del análisis visual, ya del tratamiento digital, extendiendo al resto de la imagen la experiencia acumulada en el muestreo de campo realizado previamente.

8. Revisión de campo, para la verificación de resultados, de acuerdo al porcentaje de fiabilidad requerido y a la tasa de error tolerable en el muestreo (ver cap. 8). Esta fase puede también simultanearse con la (vi) siempre que no se empleen las mismas áreas para clasificar/calibrar y para verificar/validar la imagen.

9. Restitución. Una vez obtenidos unos resultados suficientemente fiables, se trata de otorgar validez cartográfica a los resultados; esto es, que el documento

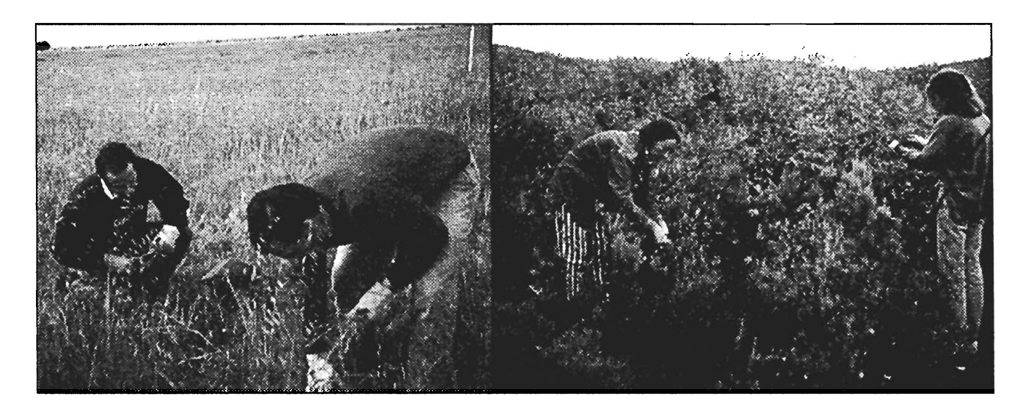


FIG. 4.8. *La obtención de datos sobre el terreno resulta clave para calibrar modelos de interpretación de imágenes.*

obtenido pueda superponerse sobre la cartografía base. Esta restitución puede ser digital o analógica, en función del método seguido en el análisis, si bien, como hemos indicado, también puede realizarse la interpretación visual a partir de imágenes ya corregidas cartográficamente.

10. Obtención de resultados e integración en un SIG. Esto supone la digitización de la interpretación visual o, en caso de tratamiento digital, las modificaciones precisas para que se ajuste perfectamente a la cartografía convencional disponible (cambios de proyección y/o resolución).

11. Inventario. Aquí se trata de cuantificar la extensión superficial de cada una de las categorías, una vez se hallen representadas sobre un mapa de escala conocida. Al igual que en la fase anterior, el procedimiento variará de acuerdo al método de análisis: conteo de frecuencias (digital), o planimetría (visual), si bien, en caso de que se hayan digitizado previamente los polígonos identificados visualmente, el inventario también se obtiene automáticamente.

12. Interpretación de la cartografía resultante, poniéndola en relación con las variables humanas y del medio físico que afectan al área de estudio.

Como puede observarse, este esquema está bastante centrado en aquellas aplicaciones que persigan elaborar una cartografía temática a partir de la teledetección, pero podría también adaptarse a la generación de variables continuas, la detección de cambios o el análisis del patrón espacial a partir de las imágenes.

CAPÍTULO 5

INTERPRETACIÓN VISUAL DE IMÁGENES

«El fanático comienza por no pedir razones y acaba por no tolerarlas.»

IZRAIL METTER, *La Quinta Esquina*

Ya en el capítulo anterior se comentaron los rasgos principales de esta labor interpretativa. Allí se presentaban las dos alternativas para analizar los datos adquiridos por el sensor: 1) abordar una interpretación visual, y 2) optar por el tratamiento digital de la imagen. En el presente apartado se estudia con más profundidad la interpretación visual de imágenes, para pasar, en los dos próximos, a exponer los principios del tratamiento digital. La mayor parte de los comentarios incluidos en este capítulo se refieren a imágenes adquiridas por diversos sensores de la familia Landsat. El amplio rango de aplicaciones que ofrecen y la extensión de su empleo justifican esta elección. No obstante, la mayor parte de las ideas aquí expresadas pueden fácilmente aplicarse a imágenes adquiridas por otros sensores, especialmente a aquellos comprendidos en el dominio óptico, y de similar resolución a los incluidos en el programa Landsat (SPOT-HRV, IRS-LISS, ASTER, CBERS, AWIFS, DMC, etc.).

1. **Familiarización con imágenes analógicas**

1.1. INFORMACIÓN INCLUIDA EN LOS PRODUCTOS FOTOGRÁFICOS

Una interpretación detallada de imágenes requiere tener en cuenta los principales rasgos de su adquisición, así como de los tratamientos que puedan haber abordado las antenas receptoras. Por ejemplo, la fecha de adquisición es fundamental para plantear hipótesis de interpretación adecuadas, considerando el ciclo fenológico de los cultivos o de las especies forestales (ritmo de las caducifolias y marcescentes). Igualmente, los ángulos solares resultan de interés para conocer las condiciones de iluminación de la zona observada y, por tanto, plantear hipótesis de interpretación en función de la combinación relieve-iluminación: laderas que se encuentran en umbría y solana y su relación con la identificación de las sombras.



FIG. 5.1. *Imagen Landsat de la costa portuguesa en el formato original de NASA (cortesía R. Núñez).*

En caso de que las imágenes se adquieran en formato digital, esta información auxiliar está incluida en archivos auxiliares o en la cabecera de los archivos de imagen. Actualmente, la mayor parte del análisis visual se hace sobre imágenes digitales, a partir de la interpretación en pantalla o imprimiéndolas previamente en cualquier periférico gráfico de suficiente calidad. Sin embargo, hasta hace unos años, lo habitual en la interpretación visual de imágenes era partir de los productos fotográficos que ofrecían las distintas agencias de distribución de imágenes, por lo que, a efectos históricos, nos parece conveniente citar las anotaciones que incluían los productos fotográficos estándar. Para las primeras imágenes procesadas por la NASA, y distribuidas por el *EROS Data Center (U.S. Geological Survey)*, las imágenes venían acompañadas de la siguiente información auxiliar (fig. 5.1):

— Fecha de adquisición (2 de febrero de 1975).
— Coordenadas del centro de la imagen (37° 21′ Norte y 8° 26′ Oeste).
— Coordenadas del punto nadir (punto de intersección entre la superficie terrestre y una perpendicular desde el centro de adquisición).
— Sensor y banda empleada (MSS, banda 7).
— Ángulo de elevación solar, medido entre la horizontal y la dirección de los rayos solares (27°).

— Ángulo acimutal, medido desde el norte geográfico y en el sentido de las agujas del reloj (143°).

— Datos del procesado (correcciones aplicadas, escala, proyección, compresión o no de los datos, etc.).

— Agencia y proyecto (NASA ERTS).

— Código de identificación de la escena (número de satélite, días transcurridos desde el lanzamiento, hora, minutos y segundos de la adquisición: E - 2011 - 10331 - 7 01).

— Marcas fiduciarias en las esquinas para localizar el nadir, cruzándolas de dos a dos en diagonal.

Debajo de estos datos se situaba una escala de grises, con objeto de comprobar la calidad de la reproducción.

En los años ochenta, otras agencias espaciales comenzaron a encargarse de la distribución de imágenes. Para toda Europa, la Agencia Espacial Europea (ESA) se responsabilizó de la recepción de los datos, gracias a sus estaciones de Fucino, Trömsø y Maspalomas, mientras el programa EARTHNET se hacía cargo de la red distribuidora. Como consecuencia de esto, se modifican las anotaciones en los productos fotográficos del satélite Landsat, ajustándose al siguiente esquema (fig. 5.2):

— Escala de grises en el borde inferior de la imagen.

— Por debajo de ella se incluía información sobre la fecha de adquisición, número de satélite, código de identificación de la escena y banda. En el caso de la figura 5.2, la imagen se adquirió el 29 de enero de 1982 por el satélite Landsat-2, la escena se reconoce por los números 217 (órbita) y 032 (fila), y corresponde a la banda 5. En el margen derecho, se sitúa el centro y fecha de tratamiento (Telespazio, 26 de mayo de 1982).

— Marcas fiduciarias.

A partir del lanzamiento de los Landsat-4 y 5, se volvió a modificar la información auxiliar que incluían los productos fotográficos, enriqueciéndose notablemente frente al anterior formato. Se recogían los siguientes datos (fig. 5.3):

— En la cabecera del negativo se señalaban los datos más importantes de la adquisición: fecha, satélite, sensor, número de banda, código de la escena y, en su caso, número de cuadrante. En el caso de la figura 5.3, se trata de una imagen adquirida el 2 de agosto de 1984, por el satélite Landsat-5, sensor TM *(Thematic Mapper)*, correspondiente a la banda 1, traza 201, fila 032, cuadrante 2.

— En el borde inferior, aparecía la escala de grises (indicando, además, el valor digital al que corresponde cada intensidad), centro y fecha de proceso y escala gráfica.

— Por fin, la última línea del negativo incluía algunos datos auxiliares, como la fecha de adquisición, coordenadas del centro de la escena, ángulo de elevación y acimut solar, nivel de corrección radiométrica y geométrica, e identificación de la escena, en el código NASA y en el sistema europeo.

— Marcas fiduciarias.

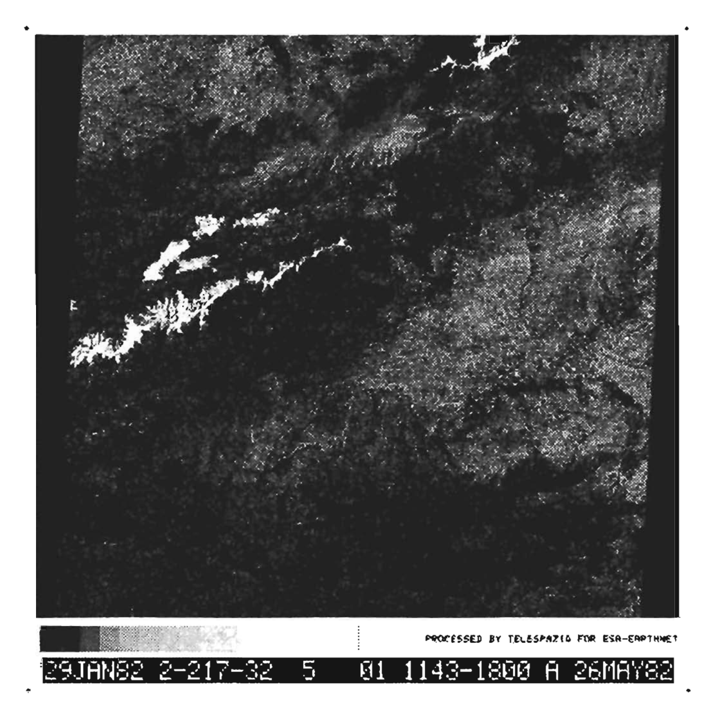


FIG. 5.2. *Imagen Landsat en el formato original de la E.S.A.*

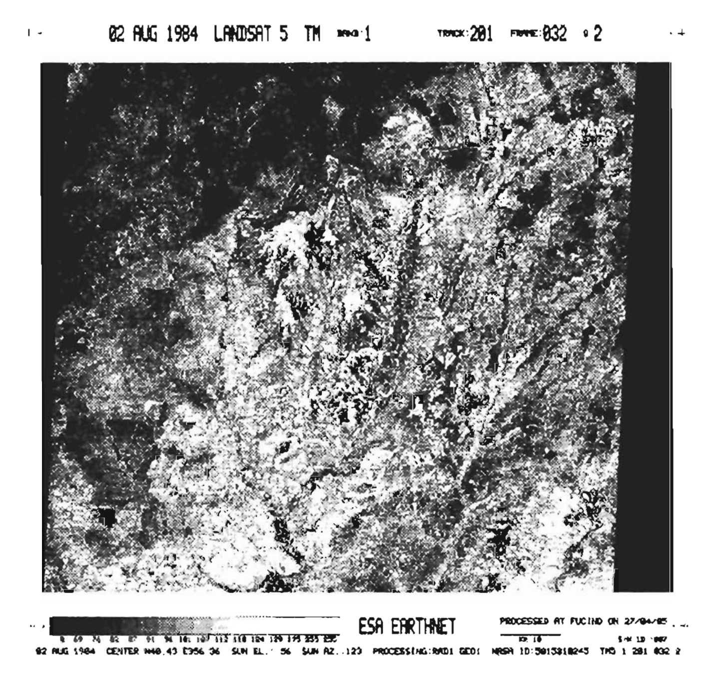


FIG. 5.3. *Imagen Landsat-TM en el formato posterior de la E.S.A.*

1.2. Identificación de algunos rasgos geográficos sobre la imagen

Una primera forma de familiarizarse con las imágenes es compararlas con una fuente cartográfica convencional. Este ejercicio puede abordarse en varias fases. En la primera, apoyándose en un mapa de similar escala, pueden situarse los embalses y cursos de agua más importantes de la zona. A partir de ellos, una segunda inspección de la imagen permite identificar aspectos humanos del territorio, como son las ciudades más importantes y las principales vías de comunicación. Los accidentes montañosos se identificarán en una tercera fase, puesto que se trata de aspectos representados más abstractamente en el mapa y, por tanto, de difícil delimitación. Masas de vegetación o rasgos efímeros relacionados con la imagen (como, por ejemplo, incendios o agentes contaminantes), podrán interpretarse en una última fase, puesto que rara vez vendrán recogidos en el mapa. Este ejercicio puede realizarse a partir de las carto-imágenes que producen distintos centros cartográficos.

Esta primera familiarización sirve de preámbulo para considerar los principales criterios que se utilizan para interpretar visualmente una imagen. Muchos de ellos son comunes a la fotointerpretación clásica de fotogramas aéreos.

2. Criterios para la interpretación visual

Como ya indicamos, una de las principales ventajas del análisis visual sobre el digital es su capacidad para incorporar a la interpretación de la imagen criterios complejos. Mientras el tratamiento digital se basa, casi exclusivamente, sobre la intensidad radiométrica de cada píxel —en las distintas bandas utilizadas para la interpretación—, el análisis visual puede utilizar otros elementos, como son la textura, estructura, emplazamiento o disposición, muy difíciles de definir en términos digitales, aunque se esté trabajando intensamente en esta línea, como luego tendremos ocasión de analizar (ver cap. 7.2.3.5).

Estos criterios nos permiten discriminar categorías con un comportamiento espectral parejo, aunque con un significado temático bien distinto. Por ejemplo, algunos cultivos en regadío suelen ofrecer una respuesta espectral muy parecida a los parques urbanos, ya que ambas cubiertas están formadas por las mismas o similares especies vegetales. Sin embargo, su significado temático es claramente distinto, y así debe incluirse en la cartografía final. Digitalmente la distinción es compleja, pues los valores numéricos de ambas cubiertas son muy similares. Ahora bien, basta incorporar un criterio visual sencillo, como es el contexto geográfico, para separarlas.

Entre las pautas visuales manejadas en teledetección espacial, algunas son comunes con la fotografía aérea —tono, textura, estructura, sombras, contexto, etc.—, otras son más propias de las imágenes espaciales, principalmente en lo que atañe a la dimensión multi-espectral y multi-temporal de las observaciones, severamente limitada en fotografía aérea. Un último grupo corresponde a criterios tradicionales en foto-interpretación que rara vez resultan accesibles en imágenes espaciales, como es el caso de la cobertura estereoscópica, tan vital para estudios del relieve. En cualquier caso, ya sean nuevos o tradicionales, los criterios visuales deben manejarse

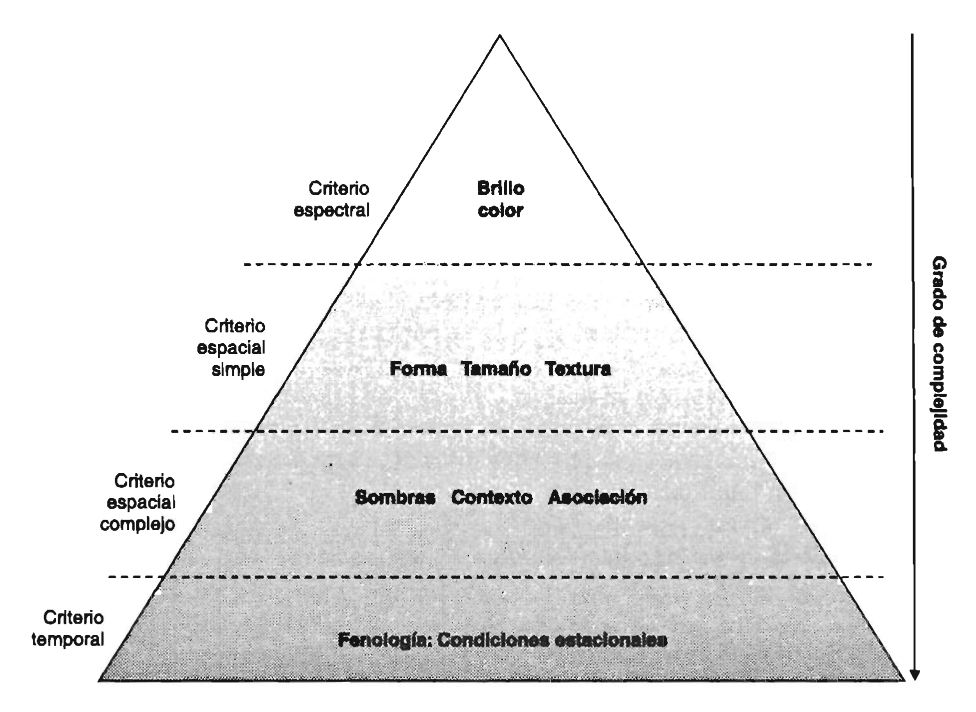


FIG. 5.4. *Organización jerárquica de los criterios de interpretación visual (adaptado de* European Commision, 1993*).*

con cierta precaución en imágenes de satélite, por cuanto las escalas de trabajo y la geometría de adquisición son distintas a las empleadas en fotografía aérea. Según vayan disponiéndose de imágenes de mayor resolución espacial, estas diferencias se irán atenuando, hasta convertirse prácticamente en inexistentes.

Conviene tener en cuenta que esos criterios se utilizan de modo integrado, en claves visuales complejas. Varios autores han sugerido clasificar esos criterios en una escala jerárquica, en función de su grado de complejidad y de las variables que se consideran (fig. 5.4) (*European Commision*, 1993). El brillo y color serían los criterios más elementales, pues caracterizan espectralmente a una cubierta, y están directamente relacionados con la forma en que reflejan la radiancia incidente en distintas bandas del espectro. La forma, tamaño, y textura tienen que ver con las propiedades espaciales de los objetos, en sí mismo considerados, mientras la sombra y el contexto (emplazamiento) también expresan aspectos espaciales, pero en este caso en relación a los objetos circundantes. Finalmente, la dimensión temporal hace referencia a cómo se modifican las cubiertas a lo largo del año (estacionalidad). A continuación revisaremos con detalle los criterios de interpretación visual más utilizados, e intentaremos engarzarlos en un esquema más amplio para entender correctamente su uso en el análisis de imágenes.

2.1. Brillo

El brillo hace referencia a la intensidad de la radiancia recibida por el sensor en un píxel, para una determinada banda del espectro. Visualmente, los píxeles con tonos oscuros indican aquellas áreas sobre las que el sensor detectó una débil radiancia (lo que indica baja reflectividad, si estamos trabajando en el espectro solar), mientras las zonas claras corresponden a zonas con una mayor radiancia. En otras palabras, el brillo se relaciona estrechamente con el comportamiento espectral de las distintas cubiertas, por lo que sus firmas espectrales, tal y como las describimos en el capítulo 2, son la base para entender la distribución de tonos de gris en la imagen resultante.

Puesto que la energía reflejada desde una cubierta varía en distintas longitudes de onda, su brillo característico también variará en imágenes adquiridas para diversas bandas del espectro. Como ya vimos, una superficie ocupada por vegetación vigorosa presentará una baja radiancia en las bandas visibles del espectro, especialmente en el azul y rojo, como consecuencia de la alta absorción de luz solar que realizan los pigmentos de la hoja en esas longitudes de onda. En consecuencia, en las imágenes adquiridas sobre esas bandas la vegetación aparecerá en gris oscuro. Por el contrario, se mostrará en grises claros si la imagen corresponde al infrarrojo cercano, ya que en esa región del espectro la hoja sana ofrece una elevada reflectividad. En definitiva, para interpretar los brillos que ofrece la imagen se ha de tener presente el comportamiento espectral de las distintas cubiertas de interés en las bandas espectrales que se estén analizando. De otra forma, el intérprete puede entrenarse a reconocer mecánicamente algunas categorías, pero no alcanzará a comprender plenamente las razones de las diferencias tonales que observa.

Para reconocer diversas categorías en una imagen multibanda convendrá reparar en el contraste de brillo que muestren. Por ejemplo, en una imagen de verano si observamos áreas con tonos oscuros en las bandas visibles y muy claros en el infrarrojo cercano, seguramente se trate de vegetación fotosintética, mientras si aparecen tonos oscuros en ambas bandas, se tratará de agua o suelos muy oscuros. Los suelos descubiertos ofrecen tonos blancos en las dos, y las áreas urbanas y las herbáceas, secas en esta época del año, grises medios en ambas (fig. 5.5). Al tratarse de una imagen de verano (Madrid02), además de los jardines urbanos, aparecen como manchas de vegetación sana los cultivos en regadío, en este caso próximos a los ríos Jarama y Manzanares. Conviene observar cómo los cultivos de regadío se observan mejor en la banda R, en tonos oscuros por la absorción fotosintética, ya que muestran mayor contraste en ese rango espectral con las áreas no cultivas de los alrededores. Mientras, en el IRC tienen un brillo similar al suelo descubierto, por lo que no se diferencian bien de él, pero sí de las láminas de agua próximas.

Con mayor experiencia en la determinación de las bandas espectrales más idóneas para cada categoría, pueden reconocerse muchos rasgos de interés: modelos de drenaje y morfología (infrarrojo cercano), trazado urbano (verde-rojo), turbidez en el agua (azul), delimitación tierra/agua (infrarrojo cercano), vegetación (rojo e infrarrojo cercano).

El brillo es uno de los principales criterios de interpretación visual. Ahora bien, el número de intensidades de gris que podemos distinguir sobre la imagen está limi-

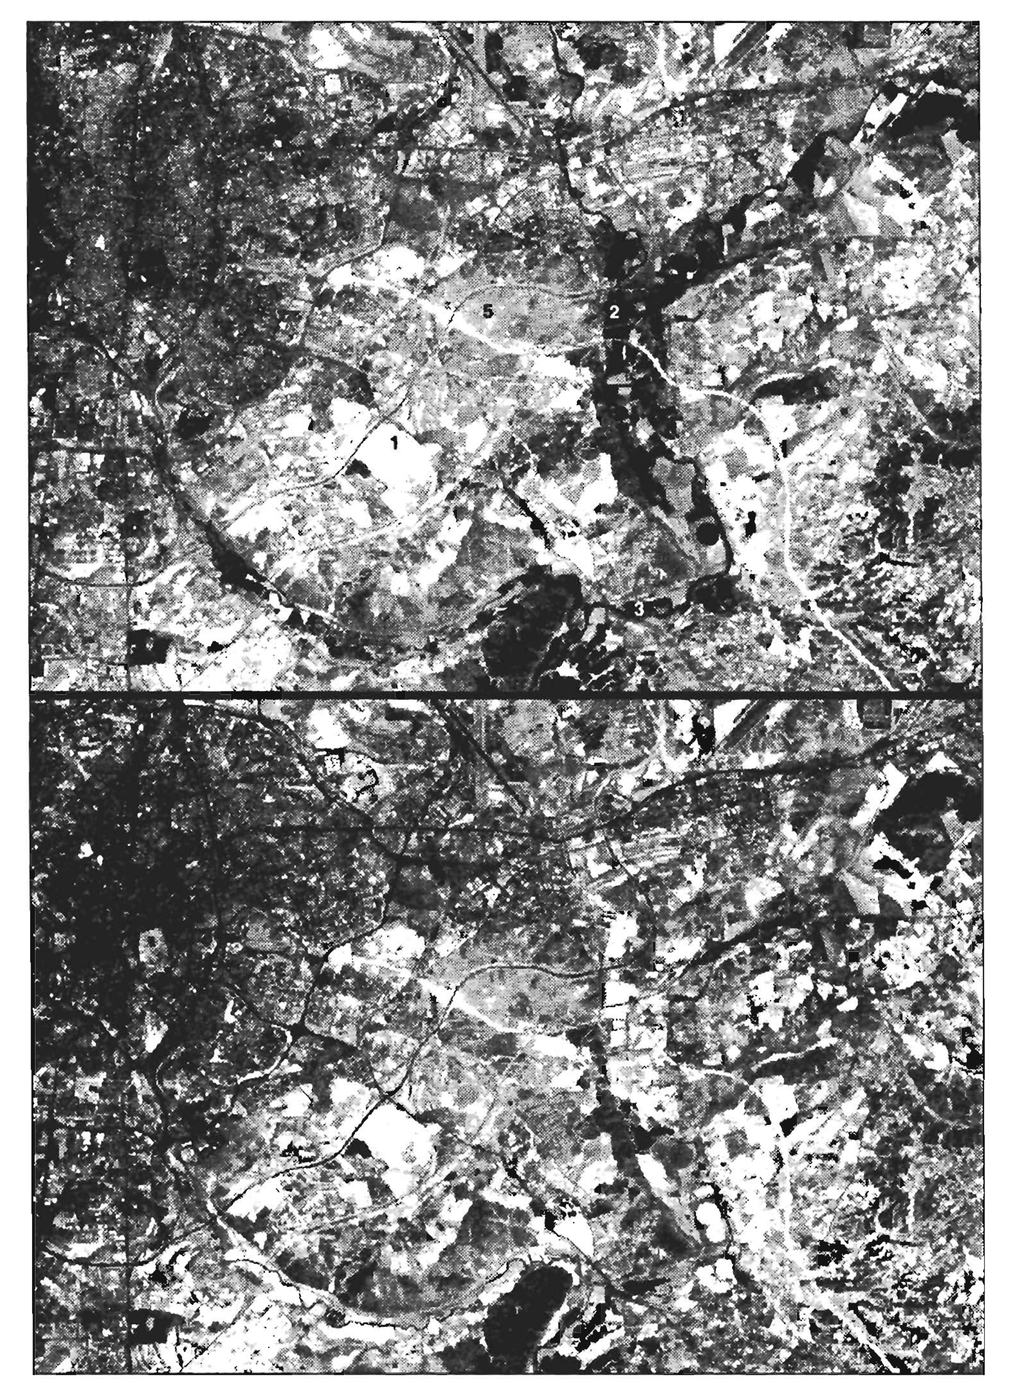


FIG. 5.5. *Variación del brillo en dos bandas en la imagen Madrid02: (1) Suelos descubiertos; (2) Vegetación sana; (3) Agua, (4) Áreas urbanas, (5) Herbáceas. La imagen superior corresponde a la banda roja (ETM3) y la inferior al infrarrojo cercano (ETM4).*

tado por nuestra propia percepción visual y el soporte físico utilizado para visualizar (papel o película). En consecuencia, la representación fotográfica de una imagen siempre supone una pérdida considerable de la sensibilidad radiométrica del sensor. De los 256 niveles de brillo —o, si se prefiere, de tonos de gris— que habitualmente facilitan los sensores espaciales (8 bits por píxel), la representación visual de esos datos sólo nos permite discriminar un número de niveles de gris mucho menor (64 en el mejor de los casos). Atendiendo sólo a este criterio, por tanto, el análisis visual sería menos preciso que el digital, ya que parte de lo que el sensor distingue nosotros no podemos diferenciarlo. Tradicionalmente, en fotointerpretación convencional las diferencias de brillo se observan en una sola banda, ya que la mayor parte de las fotografías eran pancromáticas. En el caso de las imágenes de satélite, la observación del brillo se realiza simultáneamente en varias bandas, lo que nos facilitará un reconocimiento más certero de algunas cubiertas.

2.2. Color

Varios autores han puesto de manifiesto que el ojo humano es más sensible a las variaciones cromáticas que a la intensidad luminosa (Barret y Curtis, 1999). Si a esto añadimos el aumento de información que supone la mezcla de varias bandas del espectro, fácilmente se comprende que el color resulta un elemento básico en la interpretación visual de imágenes.

Como es bien sabido, el color que aprecian nuestros ojos es fruto de la reflectividad selectiva de los objetos a distintas longitudes de onda. Aquellas superficies con alta reflectividad en el azul, y baja en el resto, aparecen con ese color, mientras ofrecen un tinte rojo si absorben las longitudes cortas y reflejan las largas. Nuestro ojo sólo percibe las longitudes de onda comprendidas entre 0,4 y 0,7 μm, separando la energía recibida en tres componentes de acuerdo a la sensibilidad espectral de nuestras células sensoras. Esos tres componentes son los denominados colores primarios: rojo, verde y azul (RVA), a partir de los cuales puede reconstruirse cualquier otro color del arco iris.

Una impresión similar al color que nosotros percibimos puede obtenerse cuando combinamos las bandas espectrales RVA, aplicando a cada una de ellas los tres colores primarios, en ese mismo orden. Esa asignación «natural» puede modificarse a voluntad del intérprete, asignado los colores primarios RVA a tres bandas espectrales cualquiera, en el orden que se estime más oportuno Obviamente, cuando no seleccione las bandas espectrales RVA, sino otras cualquiera, el color resultante no será con el que nosotros percibimos los objetos (lo que llamamos «color natural»), sino que los colores nos resultarán artificiales, de ahí que suele denominarse a estas composiciones «falso color» (fig. 11*). Esas composiciones coloreadas no se ajustan a los colores que aprecian nuestros sentidos, pero pueden ser —como, de hecho, suele ocurrir— más interesantes desde el punto de vista de la interpretación temática de la imagen.

Independientemente de las bandas que se incluyan en la composición, conviene considerar algunos aspectos sobre el proceso que permite obtener esas composiciones en color. La mezcla de tres bandas espectrales en una composición

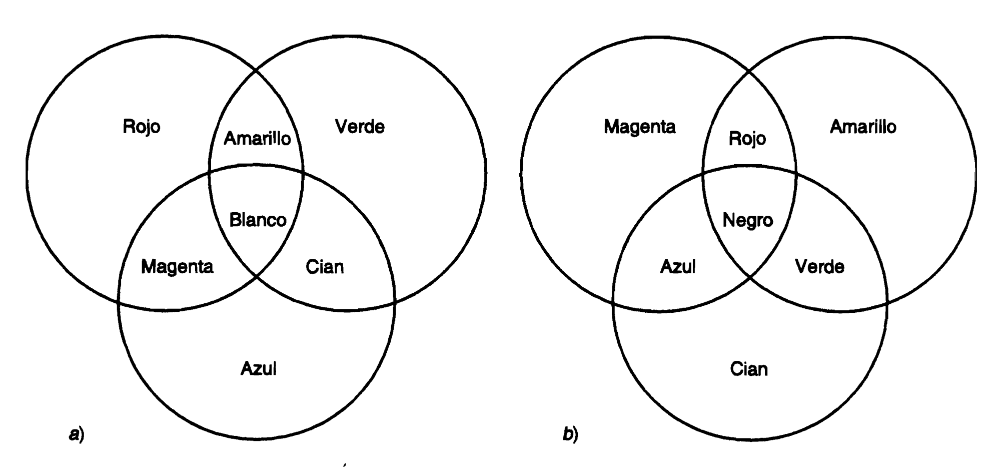


FIG. 5.6. *Procesos de formación del color:* a) *aditivo (colores primarios);* b) *sustractivo (colores complementarios).*

en color puede conseguirse de acuerdo a dos procesos, denominados aditivo y sustractivo. En el proceso aditivo, cualquier color se obtiene por suma de los tres colores elementales: azul, verde y rojo. La suma de dos colores primarios permite lograr un color complementario: azul + verde = cian; azul + rojo = magenta, y verde + rojo = amarillo, mientras los tres suman el blanco (fig. 5.6*a*). Por el contrario, el proceso sustractivo se basa en la absorción de la luz que ejercen los colores complementarios: el cian absorbe la luz roja, el magenta absorbe el verde y el amarillo el azul. Los tres en combinación suponen, por tanto, el negro (fig. 5.6*b*).

El proceso aditivo es el utilizado en los sistemas electrónicos de visualización, cuando la imagen se representa sobre un monitor. Éste es el proceso habitual en un equipo de tratamiento digital de imágenes. Por su parte, el proceso sustractivo se emplea en la reproducción mecánica del color, típica de las artes gráficas. Por tanto, cuando se pretenda imprimir una imagen resulta preciso aplicar a cada banda uno de los colores complementarios. Por ejemplo, para obtener una composición en falso color, debe aplicarse a las bandas del espectro IRC, R, V los colores complementarios amarillo, magenta y cian, respectivamente. Si, por el contrario, se requiere visualizar esa imagen sobre un monitor, el orden será rojo, verde y azul, para las mismas bandas.

Entre las múltiples combinaciones de color que se han empleado en análisis visual, la más destacada sin duda es la denominada infrarrojo color. Se obtiene desplazando hacia longitudes más largas las bandas del espectro visible, sustituyendo la composición de bandas R, V y A, por la correspondiente al IRC, R y V (fig. 11*). Su profuso empleo se relaciona con la resolución espectral de la mayor parte de los sensores espaciales. Desde el inicio de la serie Landsat, se han venido distribuyendo imágenes con esta composición en color, ya que el sensor MSS sólo incluía información de estas bandas del espectro, así como otros sensores posteriores, como el SPOT-HRV, el IRS-LISS, o el DMC, por lo que sigue siendo una composición multibanda bastante común.

De cara a facilitar su interpretación puede ser conveniente incluir una simple

clave de color, con objeto de familiarizar al intérprete con este tipo de representaciones. Las tonalidades más habituales en ella se corresponden con las siguientes cubiertas (Tindal, 1978):

— *Rojo-magenta.* Denota vegetación vigorosa, como cultivos regados, prados de montaña o bosques de caducifolias en imágenes de verano, y cultivos herbáceos de secano en imágenes de primavera. El estudio detallado de la intensidad y saturación del rojo permite identificar diversas cubiertas vegetales, así como estimar su ciclo de crecimiento y vigor.

— *Rosa.* Muestra áreas vegetales menos densas y/o vegetación en temprano estado de crecimiento. Las áreas suburbanas en torno a las grandes ciudades, con sus pequeños jardines y árboles diseminados, aparecen a veces en ese color.

— *Blanco.* Áreas de escasa o nula vegetación pero de máxima reflectividad: nubes, arenas, depósitos salinos, canteras, suelos desnudos, nieve.

— *Azul oscuro a negro.* Superficies cubiertas total o parcialmente por agua: ríos, canales, lagos, embalses. En zonas volcánicas, los tonos negros pueden asimismo identificar flujos de lava.

— *Gris a azul metálico.* Ciudades o áreas pobladas, si bien puede asimismo tratarse de roquedo desnudo.

— *Marrón.* Vegetación arbustiva, muy variable en función de la densidad y del tono del sustrato. Los tonos más oscuros indican presencia de materiales paleozoicos (pizarras), mientras los matorrales calcícolas, menos densos normalmente, ofrecen una coloración más clara.

— *Beige-dorado.* Identifica zonas de transición: prados secos, frecuentemente asociados con el matorral ralo.

Cuando se comenzaron a adquirir imágenes del sensor TM, se abrió la posibilidad de diseñar nuevas composiciones, como la correspondiente al color natural (R, V, A), mientras sus nuevas bandas en el SWIR e IRT ampliaron notablemente las posibilidades de obtener composiciones en color. Con motivo de ello, varios autores han intentado establecer algún indicador, más o menos objetivo, que ayude a seleccionar las bandas más idóneas para una composición en color. Los criterios más estudiados son los de tipo estadístico: análisis de componentes principales, índice óptimo de máxima variación, y obtención de los ejes del elipsoide de variación (ver 6.5.2).

En el terreno del análisis visual, también se han efectuado algunos ensayos para identificar la composición de color que ofrece una mejor discriminación de cubiertas. Se parte de seleccionar intérpretes con distintos grados de experiencia, para cuantificar el número de cubiertas que discriminan adecuadamente en distintas composiciones de color (Benson y Degloria, 1984; Trolier y Philipson, 1986). En estas pruebas, y para el caso del Landsat-TM (o ETM+), las combinaciones más puntuadas incluyen una banda del espectro visible, otra del infrarrojo cercano y otra del medio. El orden habitual es aplicar el color rojo al IRC, el verde al SWIR o al R, y el azul al R o V (fig. 12*). Estos resultados son muy similares a los obtenidos por otros autores mediante técnicas estadísticas (Hord, 1986). A tenor de este resultado, el proyecto de cartografía de ocupación del suelo de España (dentro del programa europeo CORINE-Land Cover) seleccionó la composición TM 4/5/3 (IRC, SWIR, R)

como base para la interpretación visual de imágenes. Para objetivos parciales, puede ser interesante considerar otro tipo de combinaciones coloreadas. A partir de imágenes TM, se ha comprobado la eficacia de la composición formada por las bandas 7/4/1, para detectar zonas quemadas, de la integrada por las bandas 7/4/3 para discriminación de cultivos en regadío o zonas encharcadas, y de la constituida por las bandas 7/3/1 para aplicaciones oceanográficas. Pese al interés de estas composiciones, sigue vigente el papel protagonista de la combinación en infrarrojo color convencional (IRC, R, V).

En la fig. 12* aparecen diversas composiciones coloreadas sobre la imagen Madrid02, que permiten analizar el interés de considerar distintas bandas para interpretar unos u otros rasgos de la imagen. En términos generales puede afirmarse que el color natural ofrece un escaso contraste, presentando tonos verde-oscuros para la vegetación y pardos para las zonas urbanas y suelos descubiertos. La discriminación de la cobertura vegetal es mucho más evidente en el infrarrojo color convencional (IRC, R, V) y en el mejorado (IRC, SWIR, R). En ambos casos, la vegetación más vigorosa (jardines, zonas de regadío) aparece en tonos de rojo, ya que a este cañón de color se asigna el IRC. En tonos marrón-ocre aparecen las áreas cubiertas por perennifolios, dependiendo de la época del año en que esté tomada la imagen. En este caso, se observa de ese color el cerro del Viso, próximo a Alcalá de Henares. Asimismo, los pastizales pueden aparecer en tonos de rojo (en primavera) o en tonos verdosos, si se trata de imágenes de verano. En la combinación IRC, SWIR, R, además, resulta algo más evidente el área edificada, y contrasta mejor la vegetación natural de la que acompaña a las áreas residenciales. Las zonas en construcción (las Tablas-Sanchinarro, Terminal 4 de Barajas, Ensanche de Vallecas, R-3) aparecen en colores blancos.

Cuando se cambia el orden de la asignación de colores, lógicamente la leyenda de color antes comentada deja de tener sentido, ya que las tonalidades resultantes serán diferentes. Por ejemplo, si modificamos el infrarrojo color mejorado (IRC, SWIR, R), asignando el cañón de color verde al IRC y el R al SWIR, la vegetación más vigorosa aparece en tonos de verde, en lugar de en tonos de rojo. Este criterio es el empleado por el Instituto Geográfico Nacional para publicar su serie de cartoimágenes sobre la base de facilitar al intérprete poco experimentado —acostumbrado a ver la vegetación en tonos de verde— el análisis de la imagen. En ocasiones se denomina esta composición en color como «seudo-color natural» (fig. 12*).

2.3. Textura

Esa variable hace referencia a la heterogeneidad espacial de una determinada cubierta, en definitiva al contraste espacial entre los elementos que la componen. Visualmente se manifiesta como la rugosidad o suavidad de los tonos de gris. Cuanto más similares sean, la tonalidad será más homogénea en el interior de la cubierta, y la textura será más lisa. Por el contrario, si existe una alta heterogeneidad en los niveles de gris de esa cubierta, aparecerá como muy rugosa, con textura grosera.

La textura de una cubierta procede de la relación entre el tamaño de los objetos que la forman y la resolución del sensor. Cuando un objeto ocupa una superficie in-

ferior a 1 mm^2 (en la resolución de la imagen) no puede identificarse individualmente, sino sólo a través de la variabilidad espacial que provoca. En función del tamaño de los objetos que forman una cubierta suelen distinguirse tres tipos de textura:

1. Textura grosera, cuando los objetos están comprendidos entre 0,25 y 1 mm^2 a la escala de la imagen.
2. Textura media, objetos comprendidos entre 0,04 y 0,25 mm^2.
3. Textura fina, objetos inferiores a 0,04 mm^2.

En sentido estricto, además del tamaño de los objetos que forman una determinada cubierta, la textura con la que aparece en la imagen puede variar en función de diversos factores. Los más importantes son el ángulo de observación del sensor (una observación más aguda incrementa la rugosidad), las condiciones de iluminación (a ángulos solares más bajos el efecto de sombras es más evidente), y la longitud de onda (una superficie lisa a longitudes largas puede aparecer como rugosa en cortas). Trabajando en el espectro visible e IRC, la rugosidad se modifica principalmente en función de las condiciones de iluminación solar. Un bosque natural, por ejemplo, puede ofrecer una textura muy variada a lo largo del año, dependiendo de la altura del sol sobre el horizonte y de su desarrollo estacional.

En cualquier caso, el criterio de textura es muy importante para discriminar determinadas cubiertas que pueden ofrecer un comportamiento espectral uniforme. Por ejemplo, los frutales en regadío y las caducifolias ofrecen una reflectividad muy similar, por cuanto, en muchas ocasiones, presentan grandes afinidades fisiológicas. De esta forma, el criterio de textura puede ser el único viable para distinguirlas. Los frutales ofrecen un marco de plantación regular —lo que implica menor variedad espacial en la cubierta—, mientras los árboles de hoja caduca aparecen con un desarrollo mucho más heterogéneo. En consecuencia, los frutales presentan una textura más fina, facilitando al intérprete la separación frente a especies forestales naturales (Gordon y Philipson, 1986).

La figura 5.7 recoge un ejemplo de la aplicación del criterio de textura. Incluye un fragmento de una imagen Ikonos de Alcalá de Henares. Tanto las herbáceas regadas (A) como de los árboles próximos (B) ofrecen los mismos tonos, lo que permite diferenciarlos claramente de suelos descubiertos o tejados de edificios circundantes (C, D), que ofrecen una tonalidad mucho más clara. Sin embargo, para distinguir entre A y B resulta preciso acudir a la textura espacial, ya que las herbáceas son mucho más homogéneas espacialmente, ofreciendo por tanto una textura más lisa.

Con imágenes de menor resolución, como la pancromática ETM+ que aparece en la figura 5.8, la textura puede facilitarnos la discriminación de las áreas urbanas (A, B) frente a los espacios agrícolas (C), que siempre tendrán una textura más lisa. Entre los sectores urbanos, la textura puede permitir diferenciar los barrios donde son dominantes las viviendas unifamiliares y el parcelario minucioso (A), típico de las áreas de nueva residencia y los cascos históricos, frente a los polígonos de bloques más grandes de viviendas (B), normalmente asociados a barrios periféricos.

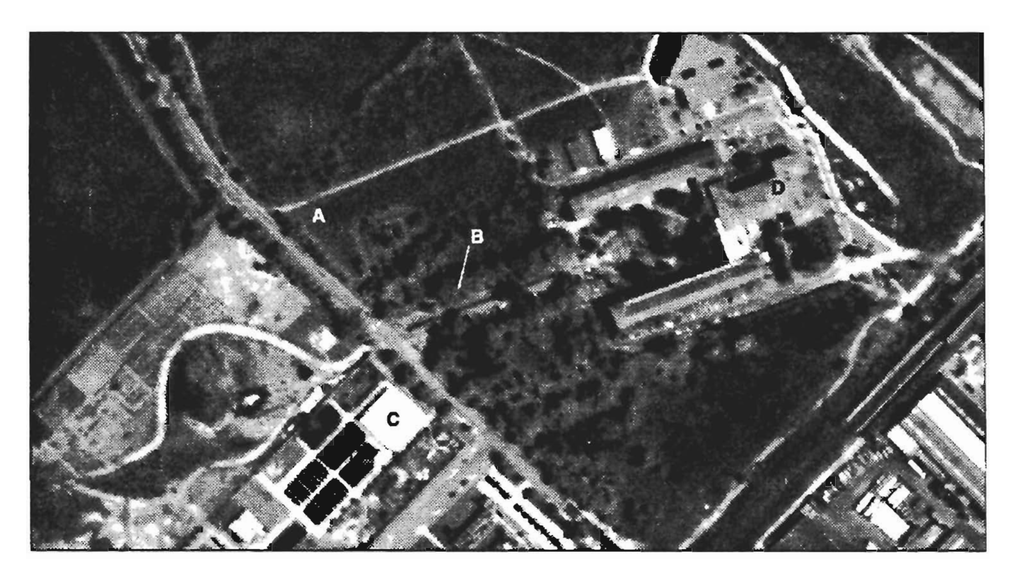


FIG. 5.7. *Fragmento de una imagen Ikonos pancromático sobre el campus de la Universidad de Alcala.*

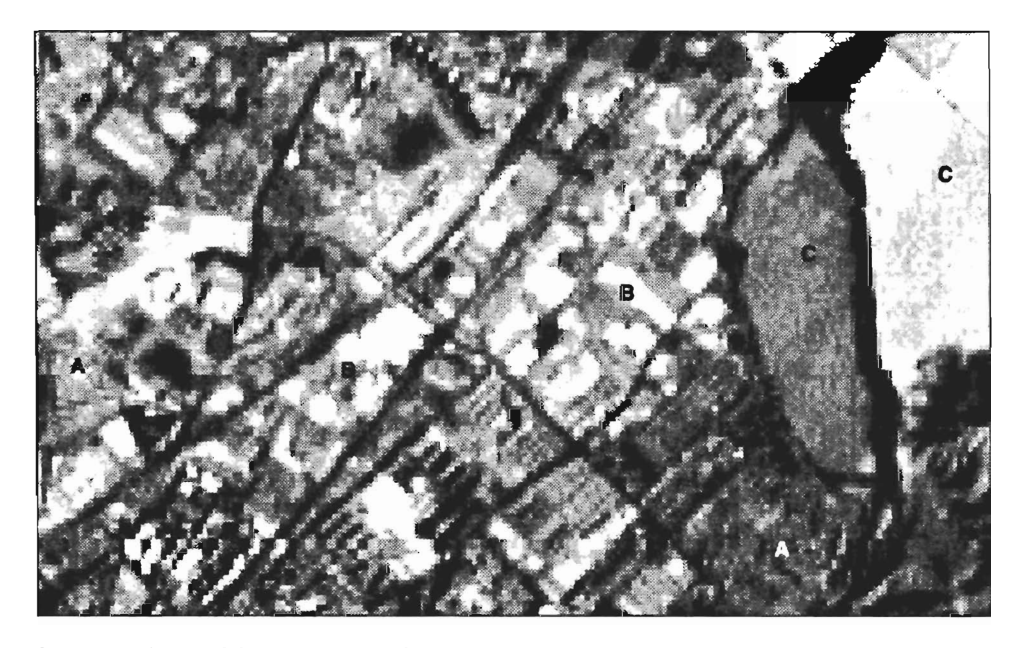


FIG. 5.8. *Sector del centro urbano de Alcalá sobre una imagen pancromática ETM+ (Alcalá99).*

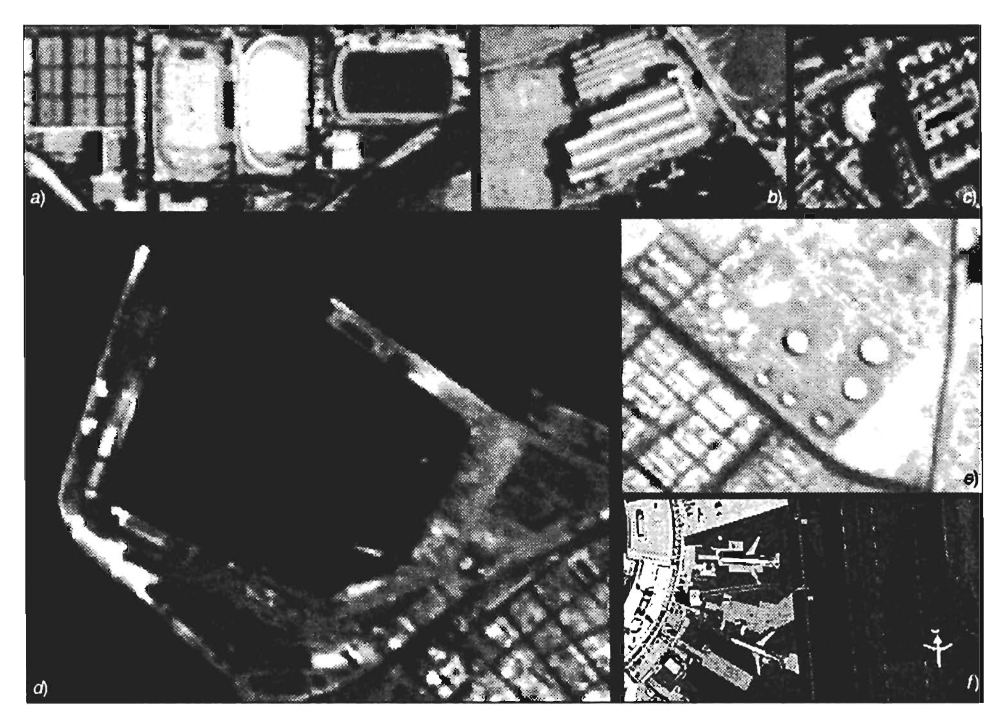


FIG. 5.9. *Reconocimiento de formas a partir de imágenes espaciales: (a) campos de deporte;* b*) fábricas;* c*) plaza de toros;* d*) puerto;* e*) tanques de combustible;* f*) aviones.*

2.4. FORMA - TAMAÑO

La forma de un determinado objeto es una clave determinante para identificarlo, ya que su contorno nos permite asimilarlo a alguno de los patrones que nos resultan familiares. Al igual que en otros criterios visuales, la forma resulta más determinante en imágenes de alta resolución espacial, ya que permite reconocer el perfil específico de muchos más objetos, limitándose sólo a los de gran tamaño en las imágenes de resolución media. A partir de la forma, por ejemplo, podemos determinar la presencia de ciertos elementos urbanos: instalaciones deportivas, centros comerciales, aeropuertos o fábricas (fig. 5.9). También facilita la discriminación entre carreteras y línea de ferrocarril (de trazado menos sinuoso), o de los ríos frente a los canales artificiales, que ofrecerán un aspecto más geométrico. También permite reconocer estructuras geológicas bien definidas: volcanes, domos o lineamientos, así como algunas perturbaciones atmosféricas (ciclones tropicales, por ejemplo: fig. 5.10).

En caso de posible duda a partir de la forma, el tamaño complementa bastante la identificación de una cubierta. Por ejemplo, la forma de un campo de tenis y de fútbol es similar, pero no su tamaño. El empleo de este criterio viene marcado por la resolución espacial de las imágenes. En aquéllas de mayor resolución pueden identificarse objetos particulares (edificios singulares), mientras en las de menor de-

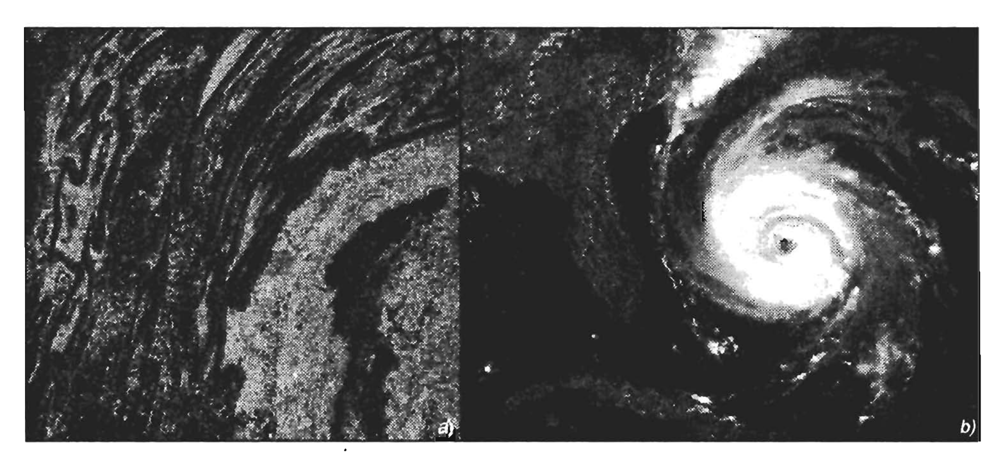


FIG. 5.10. *Empleo de la variable forma sobre grandes tamaños:* a) *relieve apalachiense sobre una imagen MSS;* b) *ciclón tropical en una imagen AVHRR.*

talle sólo pueden señalarse rangos de tamaño para ciertos tipos de superficie (embalses, áreas inundadas). A consecuencia de esa peor resolución, en ocasiones no podremos identificar la forma de un objeto determinado, pero sí de una agrupación de objetos, sirviendo a la postre para identificar un tipo de cubierta. Por ejemplo, un pinar de repoblación aparecerá con un perímetro más geométrico que un pinar natural (o fruto de una repoblación ya muy consolidada y transformada).

2.5. CONTEXTO ESPACIAL

Por situación o contexto espacial se quiere indicar la localización de las cubiertas de interés en relación con elementos vecinos de la imagen.

Un buen ejemplo del empleo de este criterio de interpretación hace referencia, de nuevo, al mundo urbano. Un jardín situado en el interior de la ciudad y formado por especies de hoja caduca, tiende a presentar un tono, un color y una textura muy similares a los que puede ofrecer un bosque natural de caducifolios. La confusión se debe a que ambas cubiertas están formadas por las mismas o similares especies, incluso con densidades y heterogeneidad (textura) muy parejas. En esa situación, no cabe más criterio para separarlas que ponerlas en relación con el entorno geográfico: aquellas que aparezcan en el interior de una superficie edificada, más o menos densa, pueden considerarse como parques urbanos, mientras las que se sitúen en un contexto de vegetación natural serán asignadas a la categoría bosques. En similares términos cabe expresarse en lo que se refiere a la separación entre árboles de ribera y otras especies caducifolias, ya que las primeras —como su nombre indica— se asocian con cursos fluviales.

En la figura 5.11 aparece un ejemplo en donde resulta especialmente evidente el criterio del contexto espacial. Se trata de dos sectores con alta actividad fotosintética en verano, ya que reciben riego externo, por lo que ofrecen tonos oscuros en la banda del R. Aunque se trata de dos cubiertas con vegetación vigorosa, su senti-

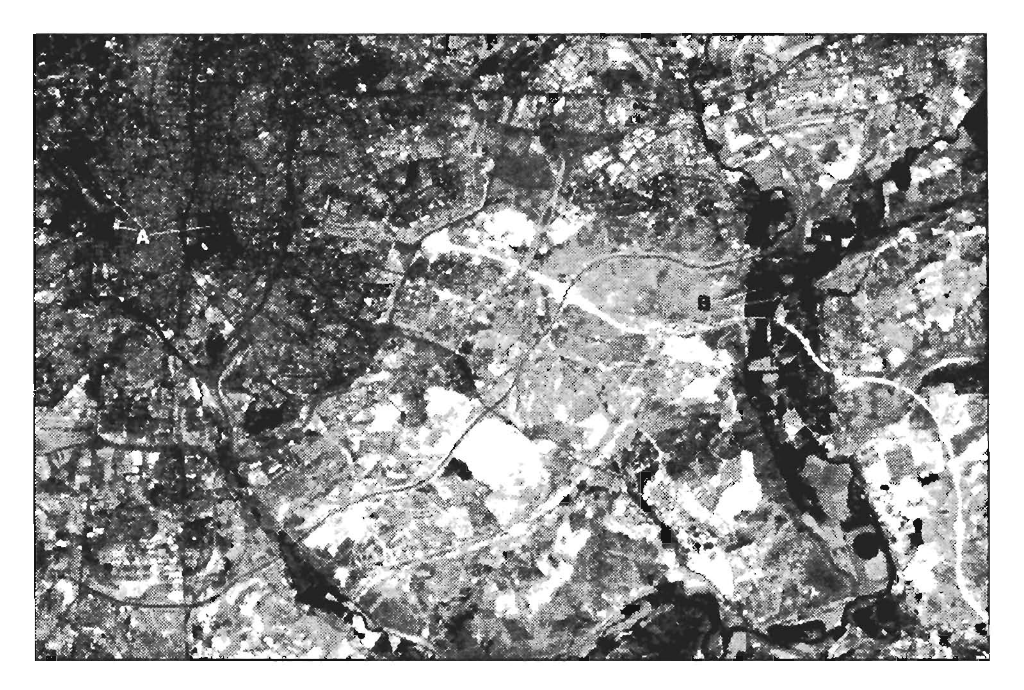


FIG. 5.11. *Fragmento de la imagen Madrid02 en la banda roja del espectro.*

do temático es muy distinto, ya que una zona alberga jardines urbanos (A), mientras la otra muestra unos cultivos herbáceos próximos al río Jarama. Ambas cuentan con similares características espectrales, pero su contexto espacial permite discriminarlas con precisión. La nieve y una zona dunar pueden ofrecer similar reflectividad en el visible, pero su contexto espacial permitirá, habitualmente, discriminarlas.

Estas distinciones, tan importantes desde el punto de vista de la cartografía temática, son más fácilmente abordables mediante interpretación visual, puesto que la clasificación digital no considera en sí el contexto geográfico, al ser muy complejo de definir en términos numéricos. No obstante, en posteriores capítulos, veremos algunas posibilidades en este sentido (cap. 7.4).

2.6. SOMBRAS

La variación de las condiciones de iluminación en una cubierta introduce una notable variedad en su firma espectral característica, de tal forma que una misma cubierta puede ofrecer valores de reflectividad bastante contrastados según se sitúe en una vertiente iluminada directamente por el sol, o en umbría. Este aspecto conviene tenerlo en cuenta, de cara a evitar señalar fronteras entre coberturas allí donde sólo hay cambios en las condiciones de iluminación. Ya veremos, más adelante, algunos criterios para corregir este efecto de cara a la clasificación de las imágenes (ver 6.6.2.3).

Ahora bien, en el campo del análisis visual, la sombra producida por la ilumi-

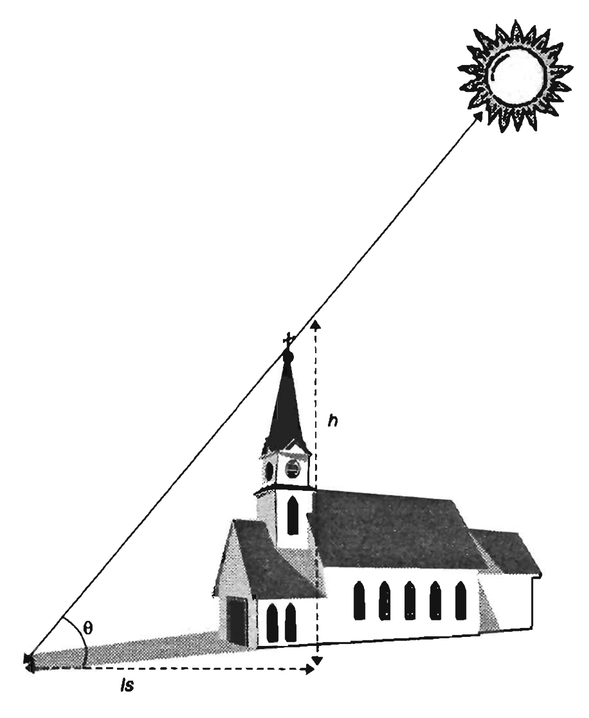


FIG. 5.12. *Esquema para el cálculo de altura de edificios a partir de las sombras.*

nación que recibe un determinado objeto resulta, en muchas ocasiones, un criterio clave para detectarlo o identificarlo, ya que nos proporciona una idea de su altura y profundidad. Además, permite realzar la interpretación de los rasgos geomorfológicos y de la textura de la imagen, especialmente en zonas forestales. Asimismo, nos permite calcular la altura de edificios, siempre que conozcamos los ángulos solares en el momento de adquirir la imagen. Basta para ello aplicar una sencilla relación trigonométrica (fig. 5.12):

$$h = \frac{ls}{\tan \theta} \qquad \{5.1\}$$

donde h es la altura del edificio, ls la longitud de la sombra y θ el ángulo cenital solar (alternativamente, puede multiplicarse ls por la tangente del ángulo de elevación). El método será más apropiado para edificios exentos, ya que en zonas urbanas densas, puede resultar complicado delimitar la sombra de un edificio singular de la procedente de otros inmuebles.

La figura 5.13 recoge un ejemplo de la aplicación de este criterio, para algunos barrios periféricos de Alcalá de Henares. La imagen corresponde a una adquisición de la cámara rusa KVR-1000. Su magnífica resolución permite calcular con bastante nitidez la longitud de las sombras, estimándose las alturas para las distintas tipologías de edificios en A ≈ 35 m; B ≈ 25 m; C ≈ 6 m, y D ≈ 8 m.



FIG. 5.13. *Ejemplo de estimación de alturas en la ciudad de Alcalá sobre la imagen Alcalá87. Las letras denotan distintas tipologías de edificios.*

2.7. PATRÓN ESPACIAL

Este concepto indica una organización peculiar de los objetos que forman una determinada cubierta. Este criterio se emplea mucho en fotografía aérea (por ejemplo, para distinguir un olivar —en plantación regular— de una dehesa). En imágenes de satélite ha estado bastante limitado como consecuencia de la baja resolución de la mayor parte de los sensores disponibles hasta hace unos años. Con el mayor empleo de los equipos de alta resolución, ganará un mayor protagonismo en el futuro. No obstante, aún sobre imágenes Landsat-ETM+, por ejemplo, puede permitirnos identificar algunas cubiertas artificiales, como serían las plantaciones forestales (que pueden presentar en la imagen una alternancia de caminos/vegetación bastante particular), o los campos de golf, que ofrecen en el infrarrojo cercano una peculiar alternancia de sectores de alta reflectividad (las calles y campos de golf) y media (la vegetación original del entorno: fig. 5.14). Similar criterio puede emplearse para identificar tipos de cobertura del suelo, estructuras geológicas o marinas.

2.8. VISIÓN ESTEREOSCÓPICA

Resulta fundamental para el reconocimiento geomorfológico y de cubiertas del suelo, pues aporta una visión tridimensional del espacio observado. Como ya hemos señalado, la mayor parte de los sensores espaciales todavía no poseen esta capacidad. Excepción a esta norma son las imágenes adquiridas por sensores fotográficos (3.3.1), o por algunos equipos de barrido espectral, como el SPOT-HRV, Terra-As-

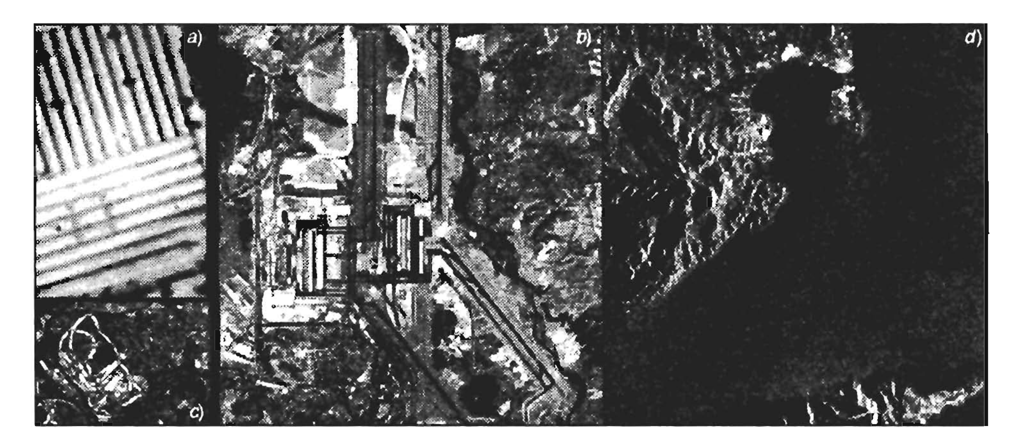


FIG. 5.14. *Ejemplo de identificación de cubiertas a partir del patrón espacial:* a) *fábricas;* b) *aeropuerto y* c) *campo de golf;* d) *estructuras oceánicas.*

ter o el Cartosat. En el resto, sólo puede obtenerse visión estereoscópica en las zonas de solape entre órbitas, restringiendo este criterio a una estrecha banda lateral del conjunto de la escena. Para la reconstrucción de la información tri-dimensional ya existen técnicas alternativas a la estereoscopía, como la interferometría radar o la medición de distancias con lidar aeroportado.

2.9. PERÍODO DE ADQUISICIÓN

La mayor parte de los especialistas están de acuerdo en que la observación sistemática de la superficie terrestre es una de las principales ventajas de la teledetección desde el espacio. Las características orbitales de un satélite permiten que las imágenes sean adquiridas periódicamente y en condiciones similares de observación, facilitándose así cualquier estudio que requiera una dimensión temporal.

Hasta el momento presente, este análisis multi-temporal se ha abordado con una doble orientación (fig. 5.15, ver cap. 7.3):

1. Por un lado, con objeto de detectar cambios entre dos fechas de referencia, deduciendo de ahí la dinámica del medio natural o las repercusiones de la acción humana sobre ese medio, y planeando, en consecuencia, las medidas adecuadas para evitar su deterioro o asegurar su mejor conservación. Este enfoque podría denominarse multi-anual, por cuanto se utiliza el factor tiempo para seguir la evolución de una zona en un período relativamente dilatado.
2. Por otro lado, podríamos hablar de un enfoque multi-estacional, en donde la dimensión tiempo se utilizaría para perfeccionar la interpretación de la imagen, gracias a incorporar información sobre el ciclo estacional de las cubiertas vegetales. Este enfoque resulta de gran utilidad para discriminar tipos de cultivos y especies forestales. Previamente, el intérprete debe conocer bien el calendario estacional de estas especies, con objeto de seleccionar los períodos más apropiados para discrimi-

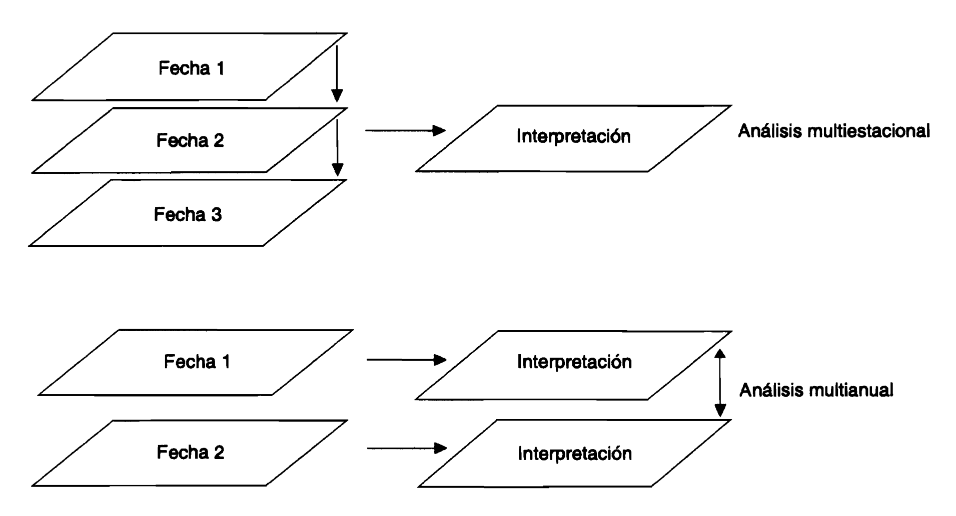


FIG. 5.15. *Dimensiones temporales en la interpretación de imágenes.*

narlas, frente a otras que pueden presentar un comportamiento espectral similar en algunos momentos del año. Algo similar ocurre cuando sólo estamos trabajando con una imagen: la fecha elegida debe ser la más idónea para conseguir separar la cubierta de interés. Por ejemplo, una cartografía de regadíos requiere trabajar con imágenes de la estación seca, mientras un estudio geomorfológico tenderá a enfatizar las imágenes de invierno, en donde son más evidentes los lineamientos estructurales por el efecto de las sombras.

Independientemente del tipo de enfoque que pretenda seguirse, cualquier estudio multi-temporal implica una labor previa de corrección, con objeto de combinar adecuadamente las dos o más imágenes que van a intervenir en el análisis. Conviene tener en cuenta que los brillos-color-textura están en relación con las condiciones medioambientales y de adquisición, por lo que no han de considerarse en sentido absoluto; esto es, resulta recomendable aplicar esos criterios a la discriminación de cubiertas en cada imagen y no al conjunto de las diferentes fechas que intervengan en el proyecto.

Con estas salvedades, el factor multi-temporal representa un criterio de identificación muy importante en análisis visual, tanto en enfoques multi-anuales (Crapper y Hynson, 1983; Eyton, 1983; Renz, 1985), como multi-estacionales (Bronsveid y Luderus, 1982; Chuvieco, 1986; Chuvieco y Martínez Vega, 1990; Hilwig, 1980).

3. Elementos de análisis visual

Tras el repaso de los criterios sobre los que se basa la interpretación visual de imágenes, nos centramos en una serie de elementos a considerar para cualquier trabajo práctico a partir de este tipo de información.

3.1. Características geométricas de una imagen espacial

Aunque una imagen adquirida desde el espacio presenta menos errores geométricos que una fotografía aérea, como consecuencia de la mayor estabilidad y altura de vuelo de la plataforma, esto no quiere decir que esté libre de distorsiones, por lo que no puede superponerse directamente sobre la cartografía básica. Más adelante trataremos de los procesos que se aplican a la corrección de estos errores geométricos (6.6.3). Basta aquí apuntar que ese desajuste está originado por tres factores: 1) por errores, propiamente dichos, en la adquisición de la imagen; 2) por la diferencia entre las proyecciones de la imagen y el mapa (la primera cónica, y la segunda normalmente cilíndrica), y 3) por la propia deformación que cualquier mapa implica de la superficie terrestre.

Una vez resueltos estos problemas, la imagen de satélite puede servir para actualizar aspectos planimétricos de la cartografía, sobre todo a escalas pequeñas y medias, dependiendo de la resolución espacial del sensor que se utilice. Existen abundantes experiencias en este sentido (Martínez Vega, 1996), no sólo en áreas de difícil acceso con métodos convencionales (Arbiol *et al.*, 1994), sino también en países con buena cobertura cartográfica (Arozarena *et al.*, 1989).

3.2. Efecto de la resolución espacial en el análisis visual

Antes se indicó que la resolución espacial hace referencia al tamaño de la mínima unidad discriminable sobre la imagen. Este concepto, en análisis visual, se relaciona tanto con el tamaño del píxel, como con la escala a la cual se representa la imagen.

La resolución espacial tiene una repercusión importante sobre la interpretabilidad de la escena. De entrada, como hemos visto, aquellos elementos por debajo del tamaño del píxel no serán identificables en la imagen, lo que supone un elemento fundamental en la selección del sensor más conveniente para cada objetivo. Además, cuanto mayor sea la resolución, mejor podrá definirse un píxel, ya que será más susceptible de albergar una sola cubierta. Por el contrario, si el tamaño del píxel es grande, la señal detectada resulta frecuentemente de varios tipos de cubierta, haciendo mucho más compleja su interpretación.

El efecto de la resolución espacial sobre la calidad final de la imagen se pone de manifiesto en el análisis de la figura 5.16. Incluye tres imágenes adquiridas por los sensores Landsat ETM+ (multiespectral y pancromático) y SPOT-HRG sobre el recinto ferial de Madrid. Se observa cómo en la banda R de la imagen multiespectral, con 30 m de resolución, apenas se distinguen los pabellones del recinto, y de forma grosera el trazado del pequeño canal que cruza el Parque Juan Carlos I. Ambos rasgos se observan mucho más nítidamente en la imagen del canal pancromático, con 15 m de resolución, donde se aprecian además varias infraestructuras y algunos sectores urbanos colindantes. Finalmente, en la imagen pancromática SPOT-HRG (2,5 m), se aprecian nítidamente los detalles del área, la urbanización del parque y diversas infraestructuras vecinas.

La figura 5.17 ofrece otro ejemplo de este efecto de la resolución espacial, en



FIG. 5.16. *Efectos de la resolución espacial sobre la interpretación de imágenes. Área cercana al recinto ferial del IFEMA, en el noreste de Madrid, adquirida por el Landsat-ETM+ (arriba) y SPOT-HRG (abajo).*

este caso en el reconocimiento de un incendio forestal que afectó a la provincia de Guadalajara en julio de 2005. Los patrones espaciales son similares en todas las imágenes, pero resultan evidentes las diferencias entre ellas en cuanto a los detalles internos que se perciben, sobre todo en el contraste entre las imágenes TM y AWIFS frente a las MERIS y MODIS, orientadas a una observación más global.

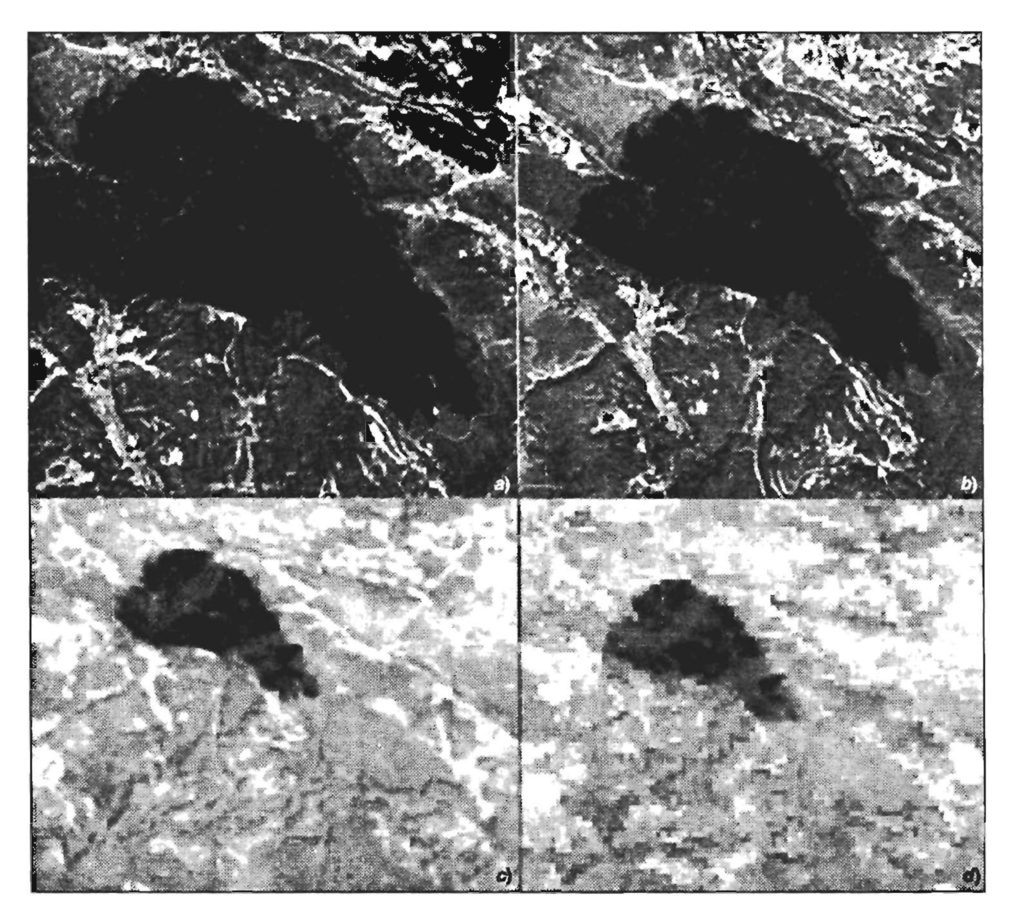


FIG. 5.17. *Imágenes de varios sensores sobre el incendio de Riba de Saelices (Guadalajara) adquiridas en agosto de 2005:* a) *Landsat-TM (30 m);* b) *IRS-AWIFS (60 m;* c) *Envisat-MERIS (300 m);* d) *Terra-MODIS (500 m) (tomado de Chuvieco* et al., *2007).*

3.3. EFECTO DE LA RESOLUCIÓN ESPECTRAL EN EL ANÁLISIS VISUAL

El carácter multiespectral de las imágenes espaciales resulta básico para su interpretación. La posibilidad de observar un fenómeno en diversas bandas del espectro amplía notablemente nuestra capacidad de reconocerlo. Como vimos en el capítulo 2, cada cubierta ofrece una reflectividad característica, que denominamos firma espectral. Ese comportamiento estándar se modifica por una serie de factores externos al sistema cubierta-sensor, estableciéndose una cierta variabilidad espectral en torno a esos rasgos genéricos, lo que dificulta, en última instancia, que pueda reconocerse automáticamente.

En cualquier caso, el conocimiento de esos rasgos espectrales resulta muy interesante para proceder a una interpretación más razonada de la imagen. Un intérprete puede acostumbrarse a observar las masas vegetales con tonos oscuros en las bandas visibles y claros en el IRC, sin considerar los factores que inciden en ese fe-

A. Zonas urbanas

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

E. Coníferas

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

B. Áreas residenciales exentas

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

F. Frondosas caducifolias

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

C. Láminas de agua

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

G. Frondosas perennifolias

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

D. Cultivos de secano

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

H. Pastizales

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

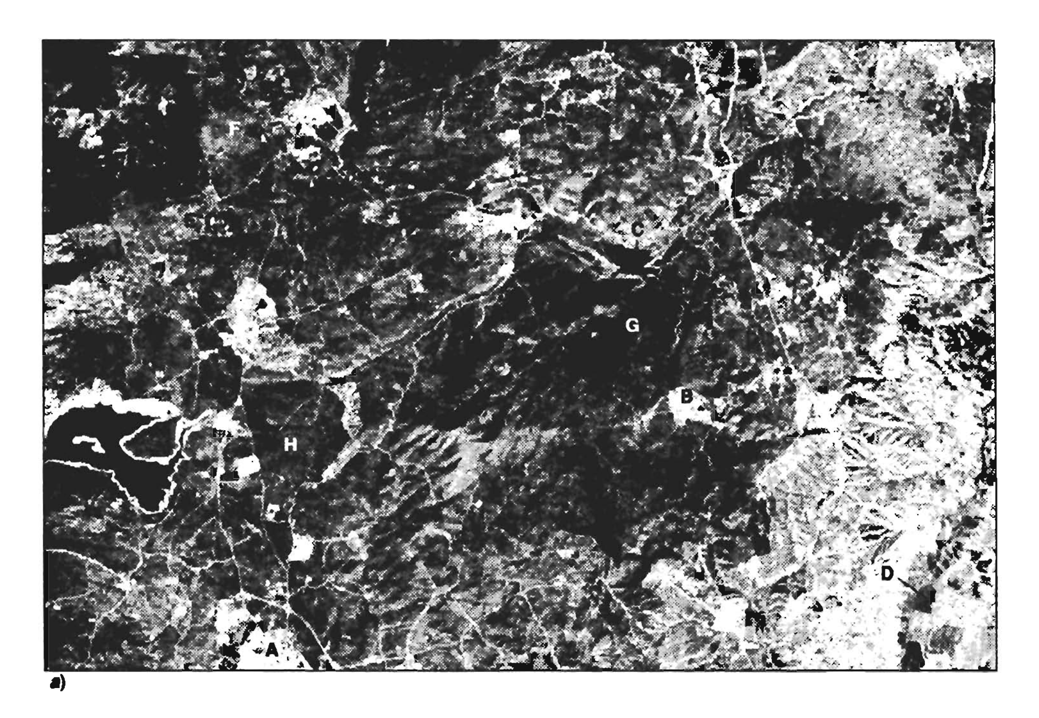
FIG. 5.18. *Gráfico para la construcción de curvas espectrales cualitativas.*

nómeno. No cabe duda que si éstos se tienen presentes en la interpretación de la imagen, resulta más fácil adaptarlos a zonas o categorías peor conocidas, convirtiendo la teledetección en una técnica aplicable a contextos más amplios.

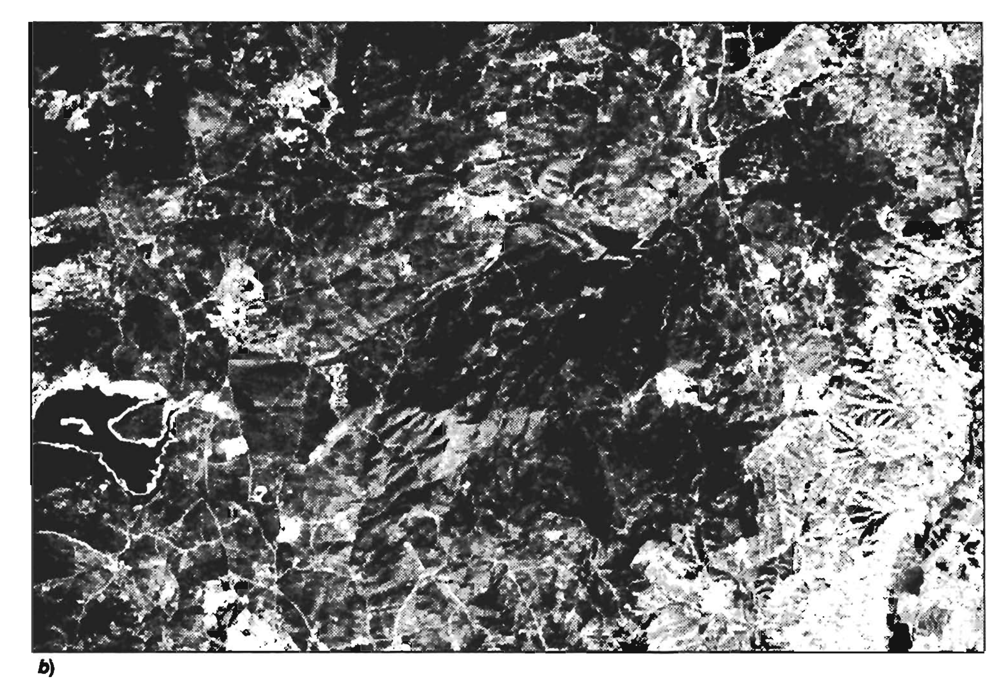
No quiere esto decir que los tonos de gris de las distintas bandas sean una traducción estricta de las curvas de reflectividad previamente analizadas. Son, más bien una representación visual de los valores numéricos almacenados por el sensor —consecuencia, a su vez, de esa reflectividad—, pero no identificables con ella, ya que cuentan también los valores de calibración de cada sensor y los efectos atmosféricos que han modificado la señal.

En cualquier caso, resulta interesante hacer ejercicios de caracterización espectral de distintas cubiertas para mejorar nuestra capacidad de reconocerlas a partir del análisis visual. El ejercicio propuesto —que se adapta de uno similar ideado por Short (1982)—, pretende que el lector complete la información incluida en la figura 5.18, a partir de los tonos de gris que observe en las distintas bandas espectrales incluidas en la figura 5.19. Se trata de las seis bandas ópticas del sensor ETM, correspondientes a una imagen adquirida por el satélite Landsat-7 en marzo de 2000. Recoge la zona abarcada por la hoja del mapa topográfico nacional denominada Torrelaguna. Por esta razón, la identificaremos como Torre100, y será la base para buena parte de los ejemplos que se presenten en los dos siguientes capítulos referidos a la interpretación digital.

Con objeto de facilitar la búsqueda de espacios que definen cada uno de los ti-



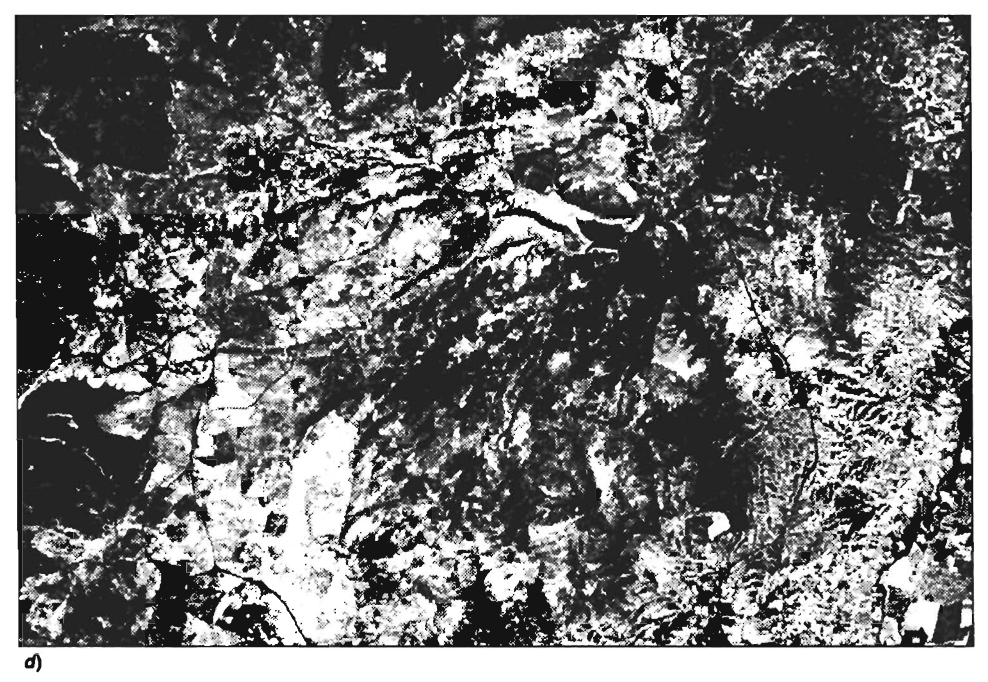
a)



b)

FIG. 5.19 *a-b. Efecto de la resolución espectral en la interpretación de imágenes:* a) *Banda 1 y* b) *Banda 2;* c) *banda 3;* d) *banda 4;* e) *banda 5 y* f) *banda 7 de la imagen Torre100.*

c)



d)

FIG. 5.19 *c-d*.

e)



f)

FIG. 5.19 *e-f*.

pos de cubierta, puede consultarse la cartografía disponible sobre este sector, si bien se han sobrepuesto unas letras, en la primera banda, que indican coberturas tipo que pueden ayudar en dicha identificación. A partir de ahí, el intérprete puede analizar los rasgos espectrales de dichas cubiertas en el resto de las bandas consideradas.

Una vez completado el gráfico, será posible responder a las siguientes preguntas: ¿es posible distinguir entre perennifolias y caducifolias considerando la fecha del año en que está tomada la imagen?, ¿en qué bandas?, ¿qué base física tiene esa distinción?, ¿qué banda es más idónea para cartografiar los cultivos de secano frente al agua?, ¿por qué?, ¿se mantendría en otra fecha del año esa separación, por ejemplo en verano?, ¿qué banda indica mejor las redes de transporte?

3.4. Interpretación de composiciones en color

A partir de este ejercicio y de la teoría del color previamente comentada, resultará más sencillo interpretar combinaciones multi-banda. Basta tener en cuenta que el proceso aditivo implica que los píxeles tendrán tanto mayor intensidad de un determinado color cuanto más blancos aparezcan en la banda a la que se aplique ese color. Si optamos, por ejemplo, por una composición en falso color (IRC, R, V), un píxel aparecerá rojo cuanto mayor intensidad presente en el IRC y menor en las dos restantes. Éste es el caso de las zonas cubiertas por vegetación vigorosa, que ofrecen un tono claro en el IRC, oscuro en el R y medio en el V, por lo que tienden a teñirse con un color rojo o rojo-magenta. Por el contrario, una lámina de agua, que aparece oscura en la banda espectral V y negra en las restantes, tenderá a mostrar un azul oscuro, ya que cuenta con un débil componente de azul y casi nulo de verde y rojo.

Siguiendo este razonamiento, y sobre la base del ejercicio espectral anterior, el lector puede contestar a las siguientes preguntas: ¿en qué color aparecerán las coníferas?, ¿y las zonas urbanas?, ¿qué combinación de color se requiere para que la vegetación aparezca en verde? En esa nueva combinación, ¿cómo aparecerían las zonas urbanas, el agua y las coníferas?, ¿qué asignación de colores complementarios se requeriría para lograr las mismas tonalidades?

En la web de este libro se incluyen algunas composiciones en color para la imagen Torre100, que servirán al lector para verificar las hipótesis que se haya planteado en el párrafo anterior.

A partir de esas imágenes, pueden realizarse una serie de ejercicios de interpretación de la imagen. Por ejemplo, los siguientes:

1. Identificar tono y textura de las siguientes cubiertas: cultivos herbáceos de secano, cultivos leñosos de secano, cultivos de regadío (dependiendo de la fecha), perennifolias, caducifolias, áreas residenciales, zonas urbanas densas, agua.
2. Con ayuda de un transparente, recorrer cada una de las carreteras principales de la imagen. Anotar qué tipo de coberturas atraviesan desde un determinado núcleo urbano.
3. Delimitar los sectores urbanos de la imagen. Distinguir entre núcleos urbanos densos y áreas residenciales exentas. Ponerlas en relación con la vegetación próxima, tipos de relieve y accesibilidad. ¿Cuál de estos factores es dominante?

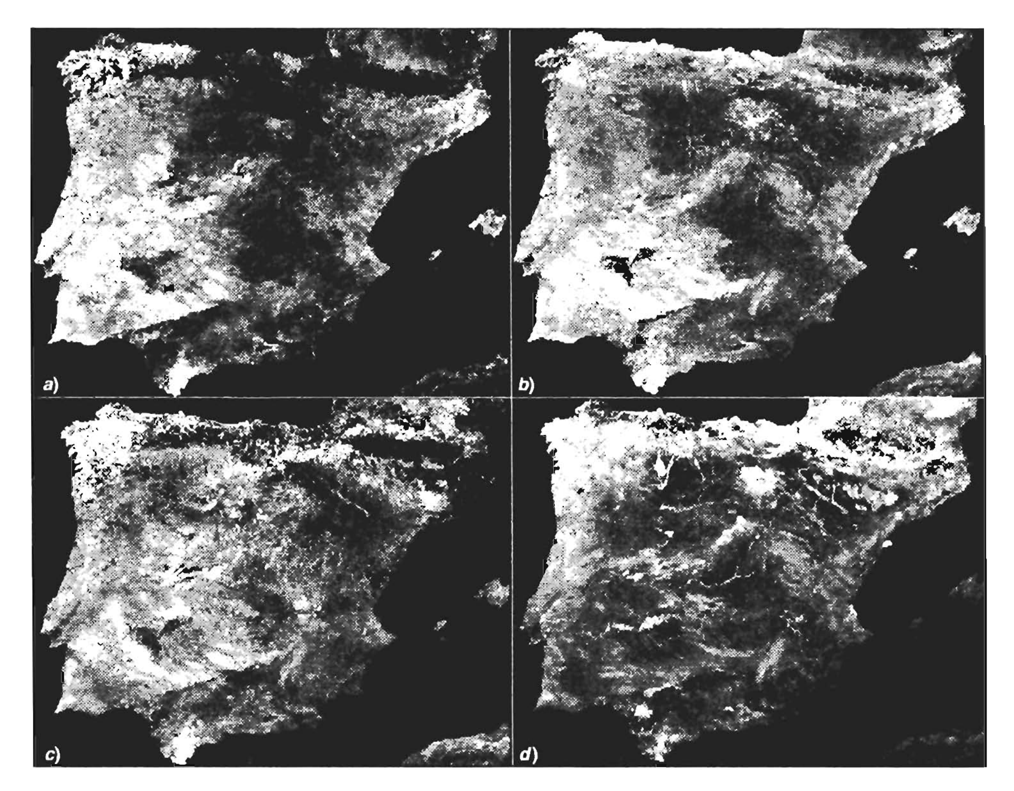


FIG. 5.20. *Compuestos multiestacionales de imágenes NOAA-AVHRR:* a) *diciembre;* b) *febrero;* c) *mayo;* d) *agosto.*

4. ¿Puede establecerse una gradación de tipos de vegetación en función de la altitud? ¿Qué tipo de especies aparecen en: pie de monte, escalón inferior, escalón superior, cumbre? ¿Pueden detectarse estas gradaciones sobre la imagen?, ¿por qué?

Un ejercicio similar puede realizarse sobre la figura 12*, centrada en el noreste de la ciudad de Madrid.

3.5. EJERCICIOS DE ANÁLISIS MULTI-TEMPORAL

Ya hemos comentado que el factor temporal puede abordarse con un doble objetivo: por un lado, reconstruir la variación estacional de la zona; por otro, la detección de cambios.

El primer aspecto supone utilizar la dimensión temporal para mejorar la interpretación de la imagen, al aportar un valioso informe sobre el desarrollo fenológico de las especies vegetales. El interés de utilizar este criterio puede orientarse a distintas aplicaciones: seguimiento de las condiciones del cultivo o el estado de los embalses podrían ser dos claros ejemplos. Por ejemplo, la figura 5.20 recoge cuatro compuestos temporales de la Península Ibérica realizados a partir de imágenes del sensor

NOAA-AVHRR. Se trata de compuestos del máximo valor del índice de vegetación NDVI (ver cap. 7.1), que indican las condiciones estacionales de la vegetación peninsular. En las imágenes de invierno, se observan las zonas cubiertas de nieve y/o nubes en tonos muy oscuros, mientras las zonas cultivadas ofrecen tonos gris oscuro a medio, y las áreas de mayor vegetación natural ofrecen tonos de gris medio a claro, indicando las zonas con mayor actividad fotosintética en esta época del año (occidente y norte peninsular, principalmente). En el mes de mayo, pese a la alta cobertura nubosa, que no está completamente eliminada en los compuestos, se observan tonos más claros para las áreas cultivadas en secano, en las dos mesetas, y un aumento de la cobertura vegetal en las regiones con mayor predominio de caducifolias (principalmente en el noreste). Finalmente, en agosto se muestran más nítidamente los contrastes entre las zonas sometidas a riego y el resto de las superficies cultivadas o cubiertas por especies perennifolias. Los regadíos del Ebro, Orbigo-Esla, Bajo Guadiana y Guadalquivir, Delta del Ebro y Albufera son especialmente evidentes.

La figura 5.21 permite realizar una observación más amplia de esta variedad estacional, al incluir dos imágenes tomadas en primavera y en verano sobre el área de Torrelaguna. Permite determinar algunos rasgos de la evolución estacional de la vegetación natural, como el contraste entre perennifolios (A) y caduficolios (B), bien obvio en la imagen de verano, pero no tanto en la de primavera; la senescencia de los pastizales (C), con menor brillo en la imagen de verano a consecuencia de su marchitez; los cultivos de regadío (D), que aparecen roturados en la imagen de primavera y vigorosos en el verano, frente a los de secano (E), que presentan la evolución contraria. También aparecen dos nubes, con sus respectivas sombras, en la imagen de verano (F), y es evidente la reducción de la lámina de agua en algunos embalses (G).

El segundo enfoque del análisis multi-temporal se dirige a detectar cambios entre dos o más fechas alejadas en el tiempo, estudiando el dinamismo temporal de una determinada zona: crecimiento urbano, transformaciones agrícolas, obras de infraestructura, etc. También nos permite evaluar la superficie afectada por fenómenos efímeros, como es el caso de inundaciones o erupciones volcánicas, así como seguir la evolución de sus efectos.

Como muestra de las posibilidades de este enfoque del análisis multi-temporal se presenta la figura 13*, que incluye dos imágenes adquiridas por el sensor TM, con ocho años de diferencia (1984 y 1992) y otra más reciente del sensor ETM+ (año 2002). La resolución espacial y espectral de las imágenes es la misma, por lo que podemos emplear esta información para delimitar los principales cambios producidos en el área metropolitana de Madrid entre las tres fechas de referencia. Los cambios más evidentes son la construcción de las autovías M-40 y M-45, para la circunvalación exterior de la ciudad, la apertura del recinto ferial de Madrid, situado entre la M-40 y el aeropuerto de Barajas, la ampliación del mismo aeropuerto, con las dos nuevas pistas, y el inicio de múltiples promociones residenciales. En la imagen de 1992, la M-40 se observa con un brillo oscuro en el tramo comprendido entre la N-IV y la N-I, al este de Madrid, mientras aparece en tono claro hacia el oeste, ya que en esa fecha este tramo aún no se encontraba pavimentado. En 2002, ya aparece de color oscuro en todo su trazado, al estar completamente pavimentada; en cambio aparecen en tono claro la R-3 y la nueva terminal del aeropuerto de Barajas.

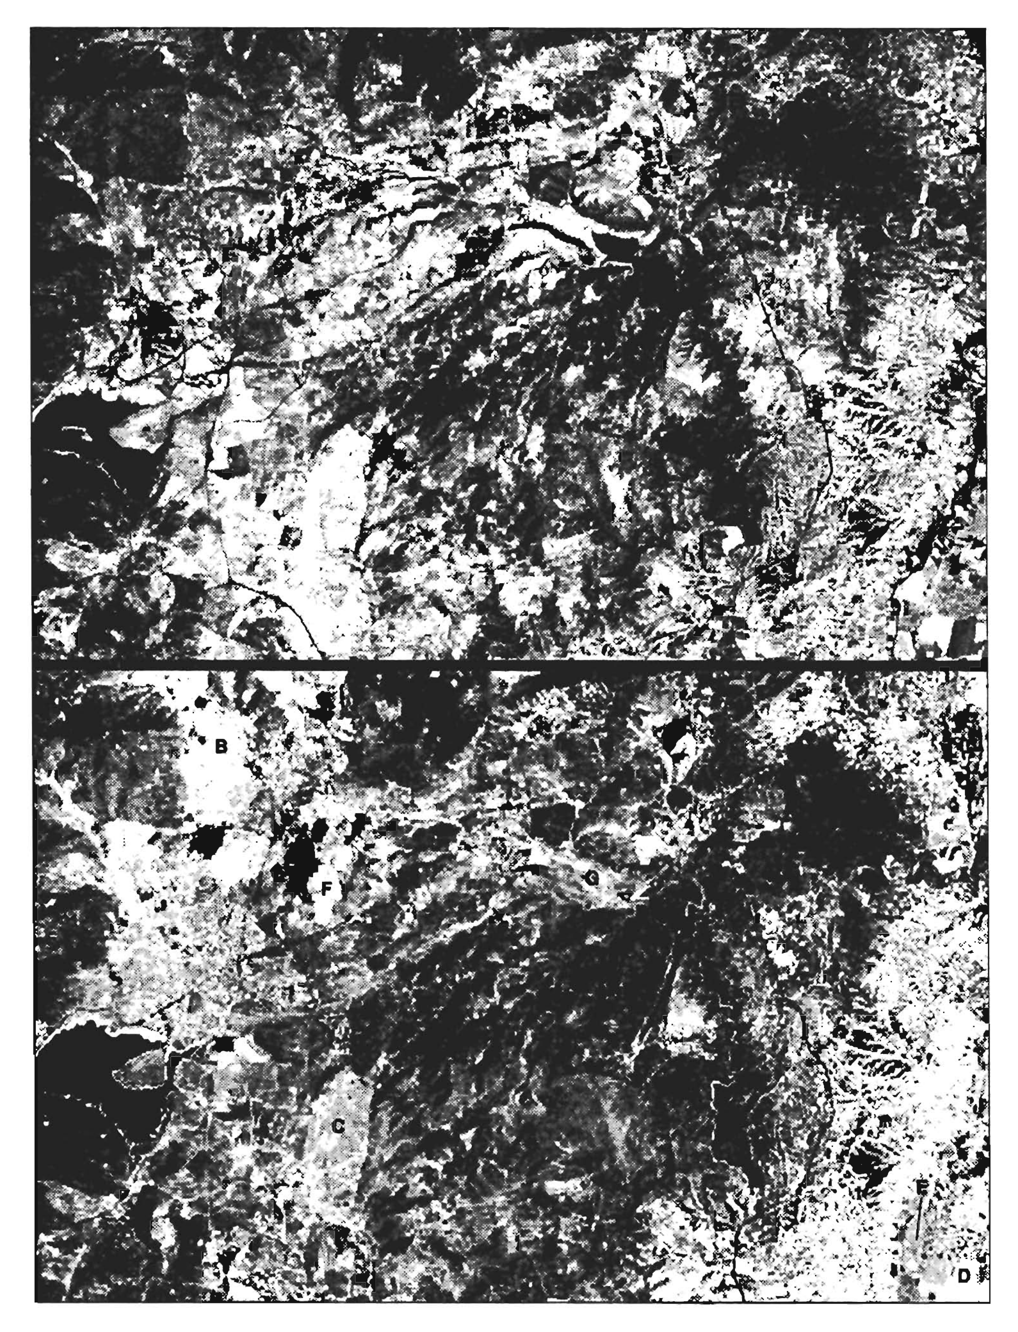


FIG. 5.21. *Imágenes de primavera (superior) y verano (inferior) del área de Torrelaguna (banda IRC).*

4. Algunos ejemplos de análisis visual

Esta obra no se ha concebido para comentar las múltiples aplicaciones de la teledetección, sino sólo para presentar sus fundamentos. Pese a ello, presentamos algunos ejemplos de análisis visual, a modo de ejercicios, para que el lector compruebe las posibilidades de este tipo de interpretación.

4.1. Cartografía geológica

A partir de imágenes espaciales, pueden detectarse rasgos geológicos de gran radio de cobertura. Un buen ejemplo sería el descubrimiento del abombamiento transversal del bloque meseteño, determinado por Alía y colaboradores a partir del análisis visual de las primeras imágenes Landsat disponibles en nuestro país (Alía *et al.*, 1976). Junto a estos fenómenos de conjunto, merecen destacarse otros aspectos más parciales, como son la cartografía de lineamientos, el estudio de erupciones volcánicas, la localización de acuíferos o de yacimientos minerales, y el seguimiento de la dinámica fluvial.

De estos aspectos, la cartografía de alineaciones ha sido el más profusamente empleado en análisis visual. Por alineación o lineamiento se entiende cualquier «rasgo lineal, simple o compuesto, de una superficie, que difiere claramente de los rasgos adyacentes y previsiblemente refleja fenómenos del subsuelo» (Moore y Waltz, 1983). Estos rasgos pueden reconocerse visualmente, a partir de la imagen original o, mejor aún, tras aplicarle alguna técnica de realce. Una vez reconocidos, pueden realizarse gráficos de frecuencia, indicando las direcciones dominantes, lo que nos permite ponerlos en relación con la estructura geológica de la zona.

Tomemos, como ejemplo, la imagen Landsat-MSS que incluye la figura 5.22, correspondiente a un amplio sector del centro de España. Con ayuda de un transparente, a partir de ella pueden dibujarse todos los lineamientos reconocibles sobre la imagen (fig. 5.23). Las direcciones dominantes están claramente relacionadas con la tectónica general de la zona.[1] Este ejercicio pasa por reflexionar, en primer lugar, sobre la estación y banda espectral más idónea para este tipo de cartografía. Respecto a la banda del espectro más conveniente para esta aplicación, se recomienda utilizar la correspondiente al IRC (banda 7 en el sensor MSS), pues los lineamientos suelen asociarse con concentraciones de humedad, nítidamente visibles en esta región del espectro. Similares trabajos se han planteado por otros autores, tanto sobre imágenes Landsat (Short, 1982, pp. 118-131; Alía *et al.*, 1976), como sobre imágenes radar (Calvet y Pascual, 1987; Woldai, 1983).

4.2. Cobertura del suelo

Este término engloba un amplio rango de aplicaciones. Por cobertura del suelo entendemos el tipo de ocupación existente sobre él, ya sea ésta vegetación natural,

1. Puede consultarse como referencia el Mapa Geológico Nacional a escala 1:1.000.000, así como la serie geológica de mayor escala (1:200.000 y 1:50.000). Entre la bibliografía de referencia, basta acudir a Terán, Solé y otros: *Geografía General de España*, Ariel. Barcelona (varias ediciones).



FIG. 5.22. *Imagen MSS de la región central española adquirida en enero de 1981 (banda IRC).*

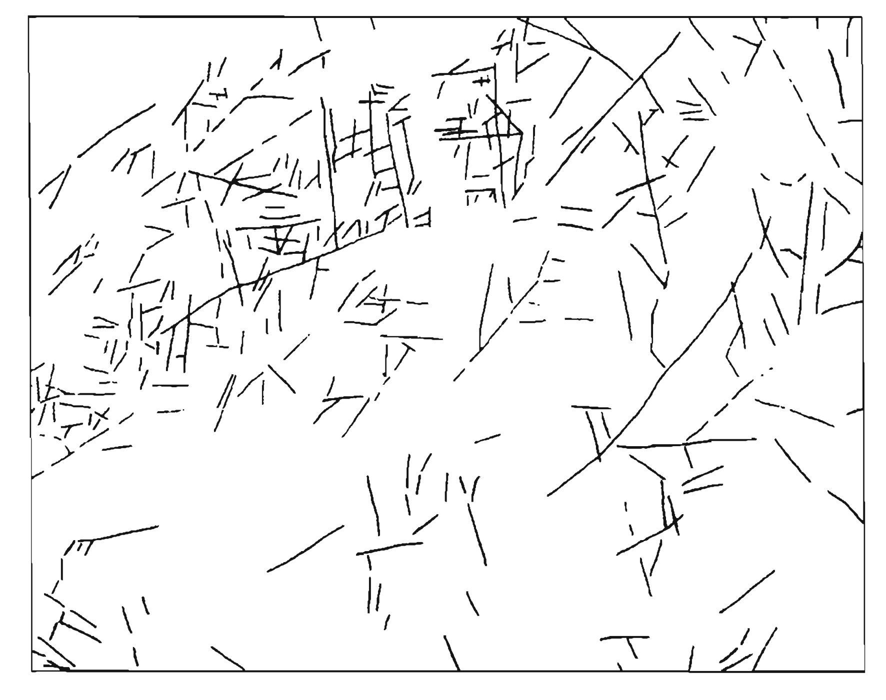


FIG. 5.23. *Croquis de lineamientos realizado a partir de la interpretación visual de la fig. 5.22.*

cultivos agrícolas o espacios urbanos. Este tipo de cartografía resulta básica en la planificación del territorio, ya que es preciso conocer la dedicación actual del terreno para proponer cualquier mejora. Con las ideas vistas en el capítulo 4, conviene organizar una leyenda coherente, a la zona y al propósito del estudio, que guíe los trabajos de interpretación visual.

Con estas ideas, el lector interesado puede ensayar una cartografía de la ocupación del suelo a partir de las imágenes en falso color que aparecen en la web. Con ayuda de unos transparentes, se tratará de ir delimitando manchas de color homogéneas, que luego pueden identificarse sobre cartografía de apoyo, fotografía aérea o trabajos de campo. Sería recomendable, al menos, discriminar las siguientes categorías: perennifolios, caducifolios, matorral, pastizales, zona urbana densa, zona residencial exenta, cultivos de secano, suelos y láminas de agua.

El análisis visual se ha empleado en numerosos trabajos referidos a la cobertura del suelo. Las áreas más desarrolladas han sido la cartografía de especies forestales (Marx y Hildebrandt, 1978; Morain y Klankamsorn, 1978; Sadar *et al.*, 1982), la estratificación fisiográfica (Astaras, 1984; Hilwig, 1980; Nikolaus, 1988), y propiamente la cartografía de ocupación del suelo (Chicharro y Martínez, 1992; Chuvieco y Martínez Vega, 1990; Harnapp, 1978). Por su alcance europeo, merece especial atención en este sentido, la cartografía de ocupación del suelo de los países miembros de la Unión Europea a escala 1:100,000 (proyecto CORINE-Land Cover), realizada a partir del análisis visual de imágenes Landsat y SPOT (Bossard *et al.*, 2000; *European Commision*, 1993; López Vizoso, 1989). Este proyecto se continúa actualmente con el Sistema de Información sobre la Ocupación del Suelo de España (SIOSE), que pretende generar un inventario actualizado de la cobertura del suelo de todo el país, a escala 1:25.000 a partir de imágenes de satélite de alta resolución (inicialmente SPOT a 2,5 m), con una unidad cartográfica mínima de 0,5 a 2 ha, dependiendo del tipo de territorio cubierto (Arozarena *et al.*, 2006).

Otros estudios de cobertura del suelo se han orientado hacia algunas clases más específicas, como por ejemplo el área quemada (Martin *et al.*, 2007), o la cartografía de paisajes (Martínez-Vega *et al.*, 2007).

Un ejemplo de la variedad de criterios visuales que incluye la discriminación de las cubiertas del suelo puede seguirse en un trabajo de este tipo desarrollado sobre la zona centro (Chuvieco y Martínez Vega, 1990). Para este caso, se emplearon en la interpretación los siguientes elementos: brillo, color, textura, emplazamiento y alternancia estacional. El trabajo pretendía realizar una cartografía de la cobertura del suelo a escala 1:250.000 sobre dos imágenes TM, de mayo y agosto. En el ensayo cartográfico se delimitaron catorce categorías: espacios urbanos densos, áreas residenciales, parques urbanos, herbáceos de secano, olivar-viñedo, cultivos de regadío, suelos no cultivados, bosques de caducifolias y de perennifolias, praderas, pastos y matorrales, superficie improductiva y agua. Algunas de estas categorías fueron claramente discriminables a partir de su coloración en la imagen de agosto, utilizada como referencia. Se trataba del agua, bosques de perennifolios y matorral. Otras se delinearon tras comparar esta imagen con la de mayo: suelos no cultivados, zona urbana densa, praderas, olivar-viñedo. El resto, exigieron una conjunción de diversos criterios. Estas categorías problemáticas fueron: caducifolios, cultivos regados, urbanizaciones residenciales y parques urbanos. En este punto, se puso en evi-

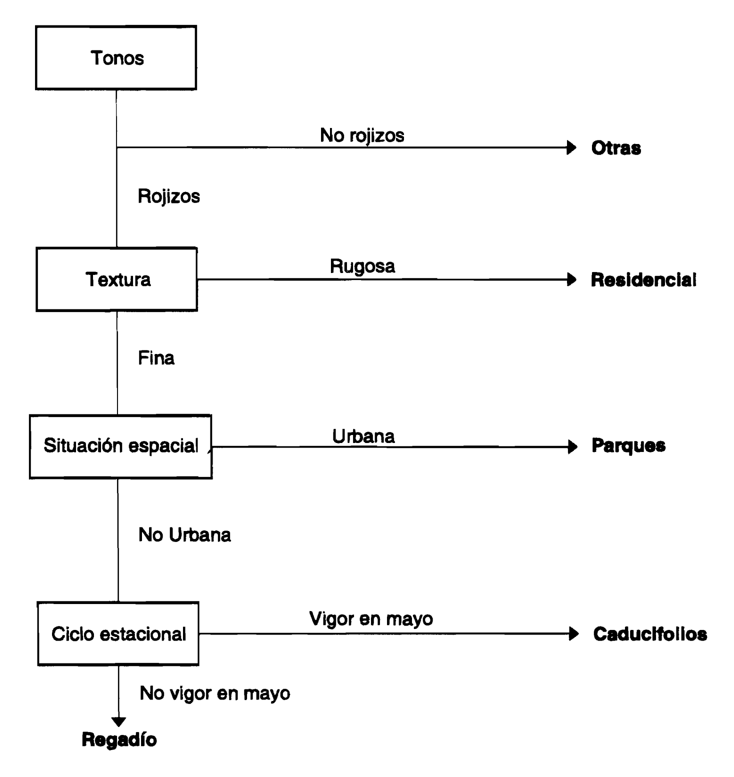


FIG. 5.24. *Un ejemplo de clave jerárquica para organizar criterios visuales en la interpretación de imágenes tomado de (Chuvieco y Martínez Vega, 1990).*

dencia el interés de contar con otros criterios visuales de identificación (fig. 5.24). La textura permitió aislar las áreas residenciales, mucho más heterogéneas que el resto de las arriba indicadas. El contexto espacial permitió separar los parques urbanos, claramente identificables por su situación. Por último, la dimensión estacional facilitó la discriminación de los cultivos regados frente a los caducifolios, ya presentes en el suelo en la imagen de mayo.

4.3. MORFOLOGÍA URBANA

Teniendo en cuenta la gran complejidad espacial del fenómeno urbano, en donde conviven actividades muy variadas sobre un reducido espacio, la aplicación de la teledetección espacial a estos ámbitos es reciente y aún limitada, si bien se ha visto notablemente beneficiada por la puesta en órbita de los sensores de alta resolución espacial.

Hasta la puesta en órbita de estos equipos los estudios urbanos con teledetección se centraron sobre áreas remotas, en donde la cartografía disponible es inadecuada. Trabajos de este tipo son los emprendidos sobre Nigeria (Adeniyi, 1987; Olorunfemi, 1987) o China (Lo y Welch, 1977). Incluso en países más desarrollados, la

cartografía de zonas urbanas ofrece importantes problemas de actualización, debido al dinamismo que normalmente presentan. La cobertura temporal de las imágenes espaciales estimula su empleo en tareas de actualización, ya sea de los límites censales (Dietrich y Lachowski, 1978), ya del espacio edificado (Carter y Stow, 1979; Herrera, 2001; Jensen y al., 1983; Molina y Chuvieco, 1997). Gracias a la mayor resolución de los satélites comerciales, estas aplicaciones urbanas están siendo cada vez más activas, puesto que este tipo de estudios requieren alta resolución (Bauer y Steinnocher, 2001; Hazel, 2001; Schiewe *et al.*, 2001; Smits y Annoni, 1999).

El análisis de la imagen para inferir rasgos de la morfología urbana requiere utilizar criterios mixtos, integrando brillo, color, textura y emplazamiento. A partir del primero puede deducirse la densidad de edificación, por cuanto aquellas zonas que alberguen menor influencia del trazado viario ofrecerán un brillo más oscuro. Asimismo, el color indica si la zona cuenta o no con espacios verdes, bien sea continuos (manchas uniformes) o discontinuos (en tinte rojo salpicado en medio de los azules propios de la edificación en caso de tratarse de una composición en falso color convencional). En cuanto a la textura, indica el grado de mezcla propio de un determinado sector. A partir de estos dos criterios, puede ensayarse una delimitación de sectores morfológicos dentro de una zona urbana (Casas y Chuvieco, 1987). Ejercicios didácticos de este tipo se han planteado por varios autores (Chicharro y Martínez, 1992; Chuvieco y Sancho, 1986).



FIG. 1*. *Imágenes Quickbird de Nueva Orleáns (USA) tomadas antes y poco después de la inundación provocada por el huracán Katrina en agosto de 2005 (www.digitalglobe.com).*

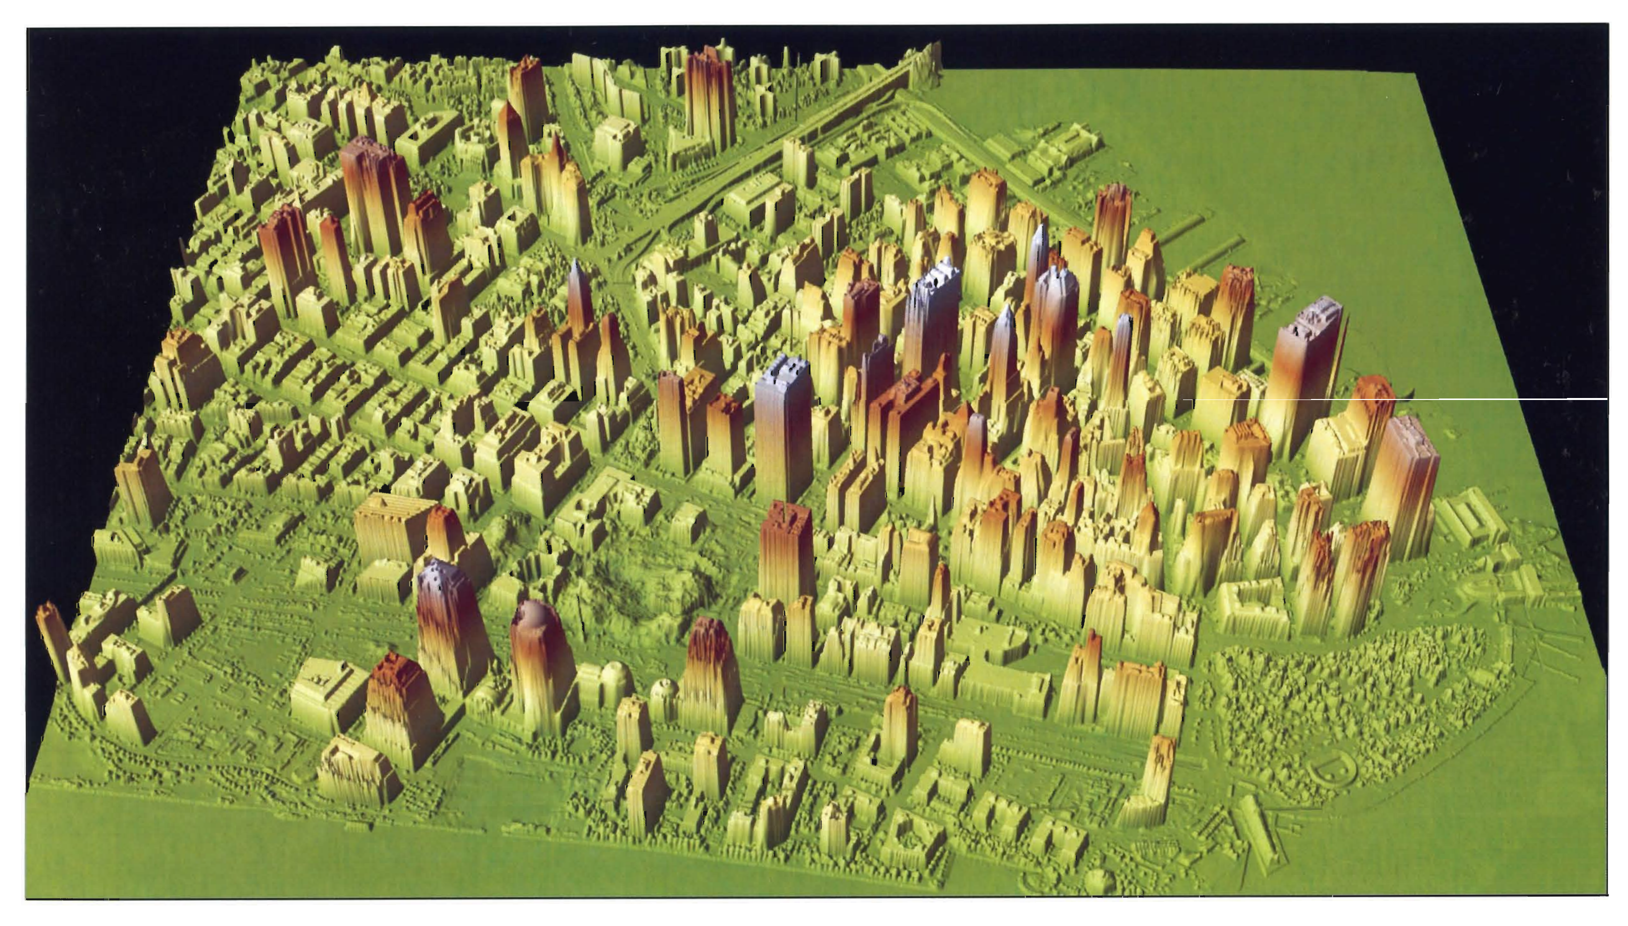


FIG. 2*. *Reconstrucción de alturas en la isla de Manhattan a partir de un lídar aerotransportado El vuelo se realizó el 23 de septiembre de 2001 (cortesía: NOAA/U.S.Army JPSD, www.noaa.gov).*

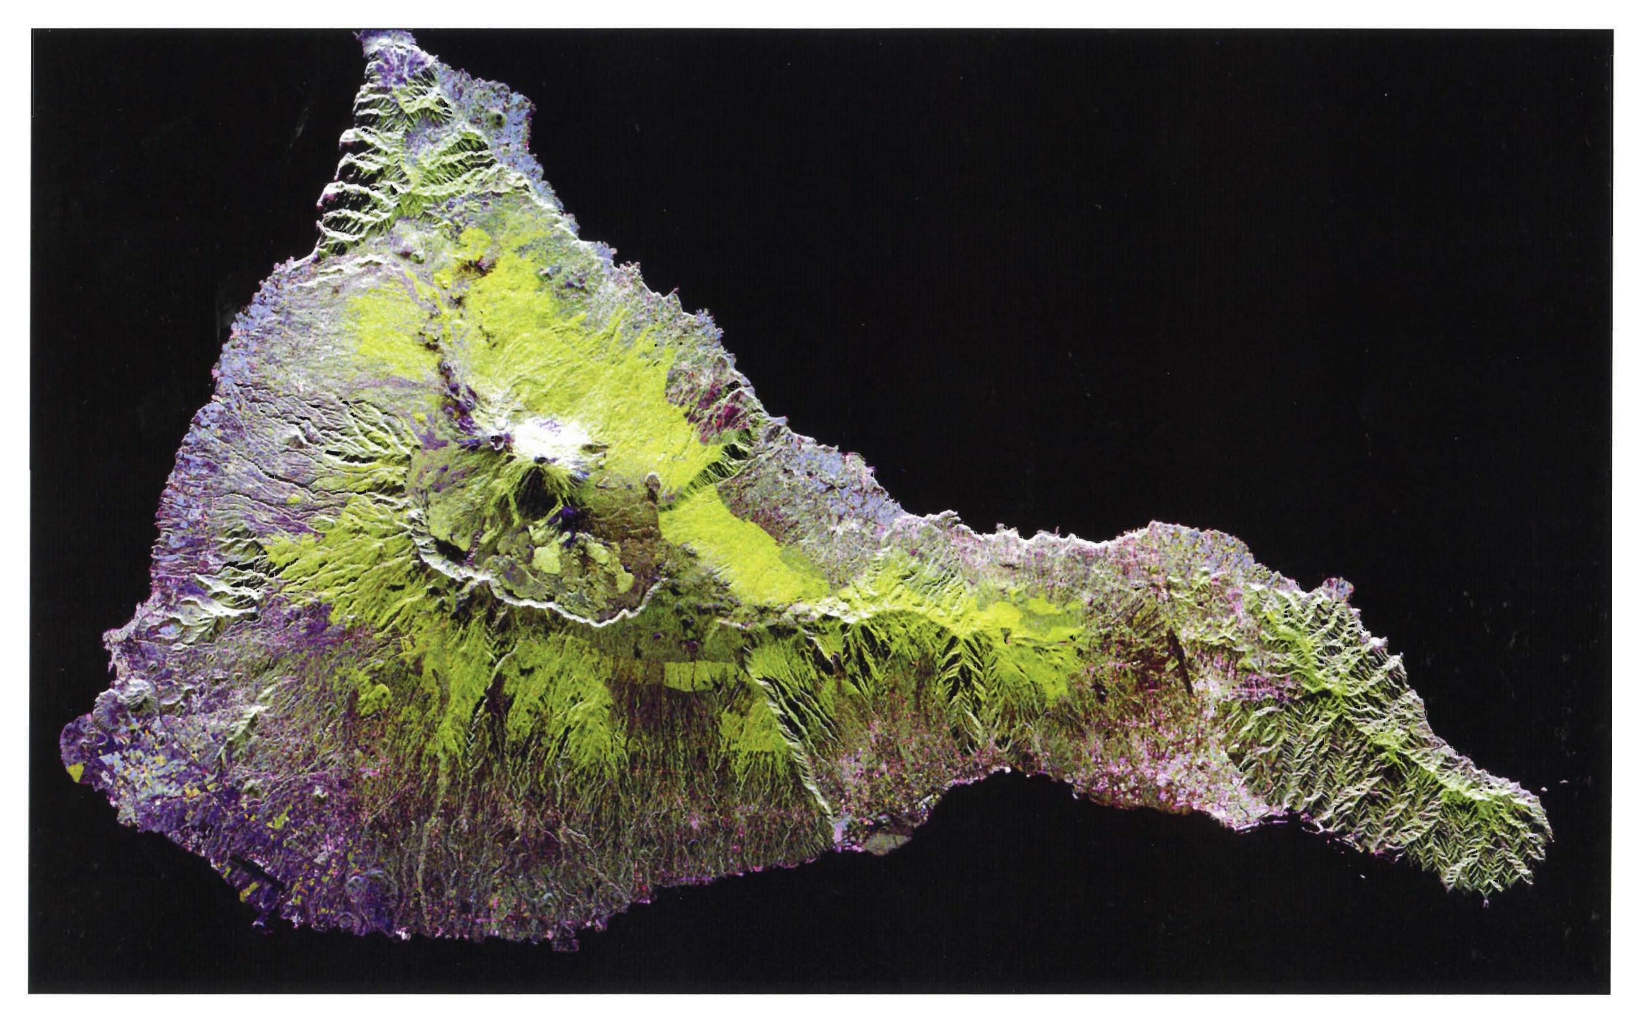


FIG. 3*. *Composición en color de una imagen radar de la isla de Tenerife, correspondiente a la misión SIR-C/X-SAR del Endeavour (11-10-1994). En rojo aparece la banda L (polarización HH); en verde la banda L (polarización HV), y en azul la banda C (polarización HV). Cortesía NASA (http://visibleearth.nasa.gov).*



FIG. 4*. *Relieve sombreado de África a partir del modelo digital generado por la misión SRTM (http://photojournal.jpl.nasa.gov/catalog/PIA04965).*

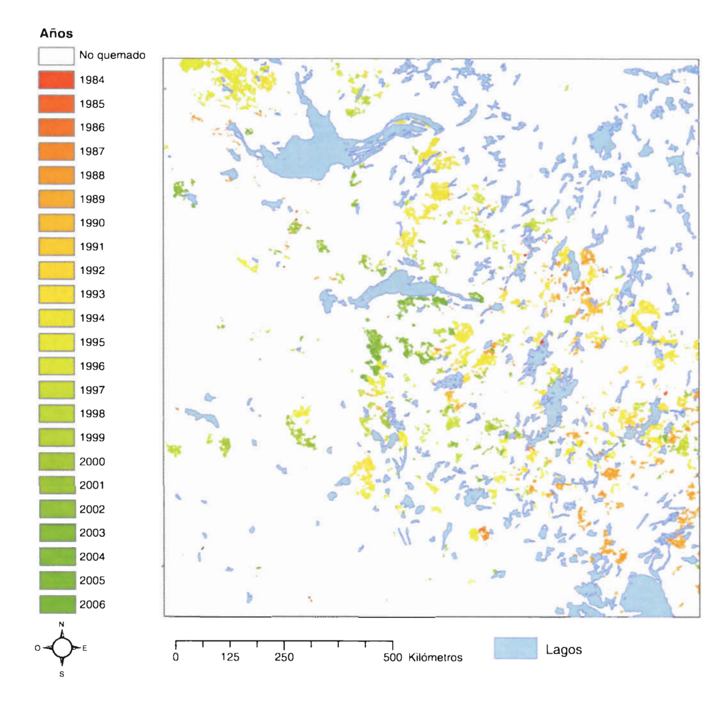


FIG. 5*. *Cartografía de áreas quemadas en el bosque boreal canadiense realizada a partir de una serie temporal de imágenes NOAA-AVHRR (tomado de Chuvieco* et al., *2008a).*



FIG. 6*. *Imagen del sensor SEVIRI, adquirida por el Meteosat-8 el 9 de mayo de 2003 que muestra el disco visible de la Tierra adquirida. La composición en color corresponde a las bandas del IRC (1,6 μm), R (0,8 μm) y V (0,6 μm), realzadas digitalmente (Fuente EUMETSAT: http://www.eumetsat.int/Home/Main/Image_Gallery/PR_Images/Fulldisk_Images/index.htm).*



FIG. 7*. *Imagen Aster del Estrecho de Gibraltar adquirida el 5 de julio de 2000. Cortesía NASA (http://visibleearth.nasa.gov).*

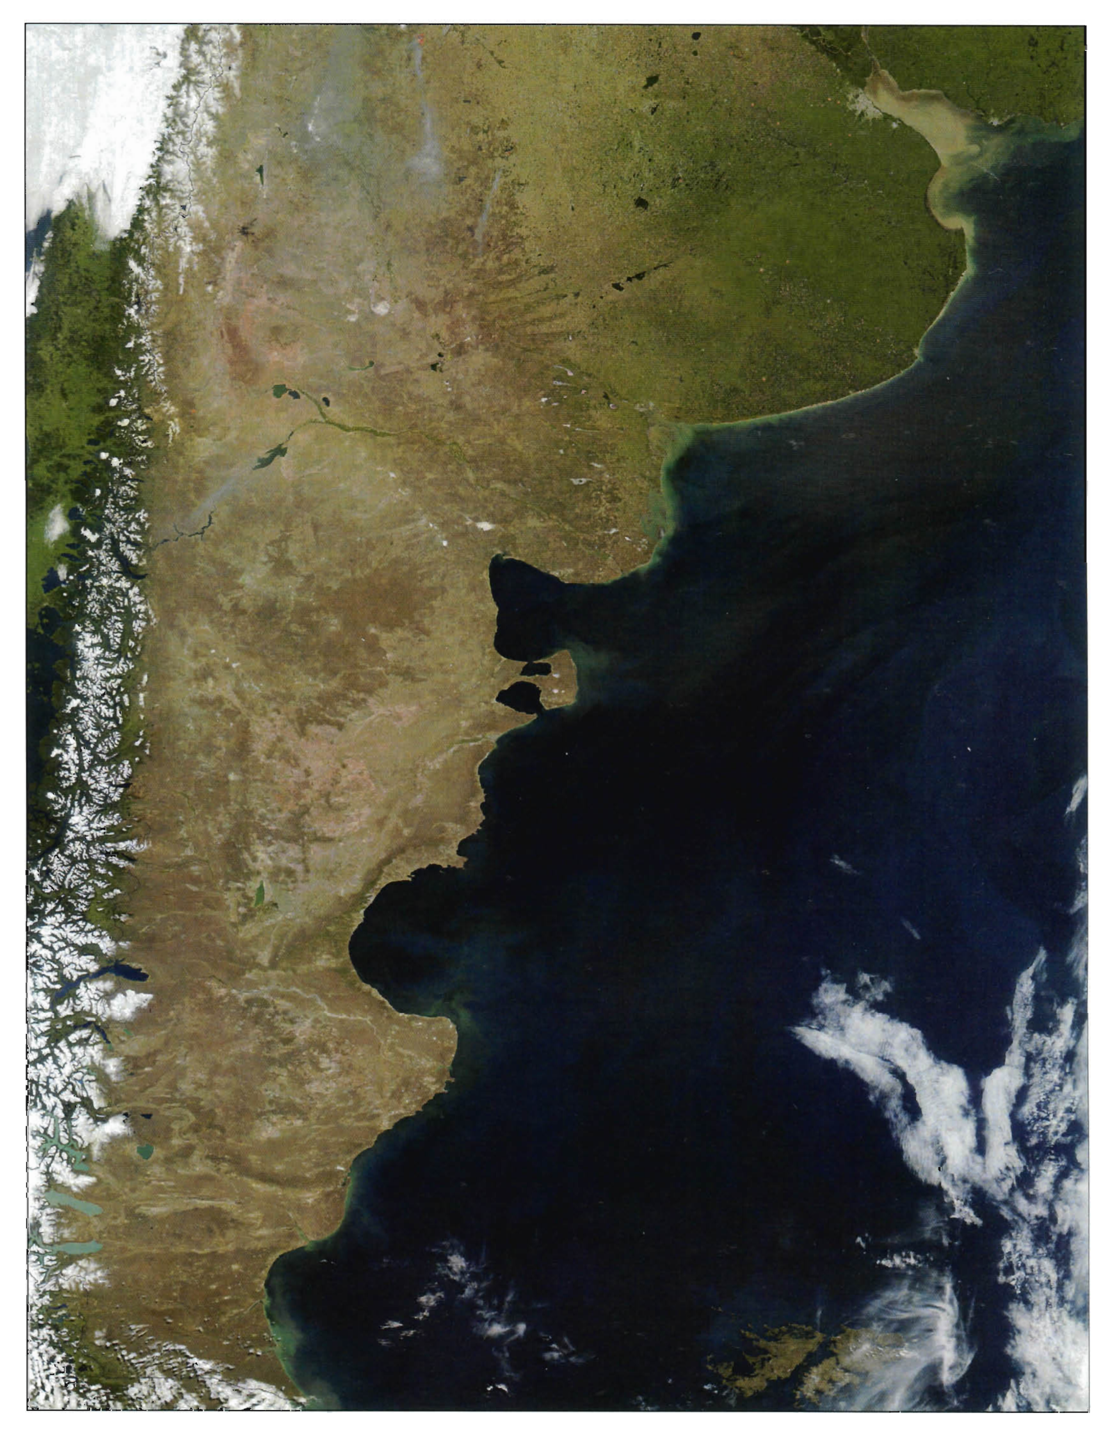


FIG. 8*. *Imagen Terra-MODIS del Cono Sur adquirida el 2 de noviembre de 2003. Composición en color real de los canales reflectivos sobre los que aparecen algunos incendios activos. La imagen se extiende desde Buenos Aires (al norte) hasta el límite con Tierra del Fuego. Fuente: http://visibleearth.nasa.gov.*

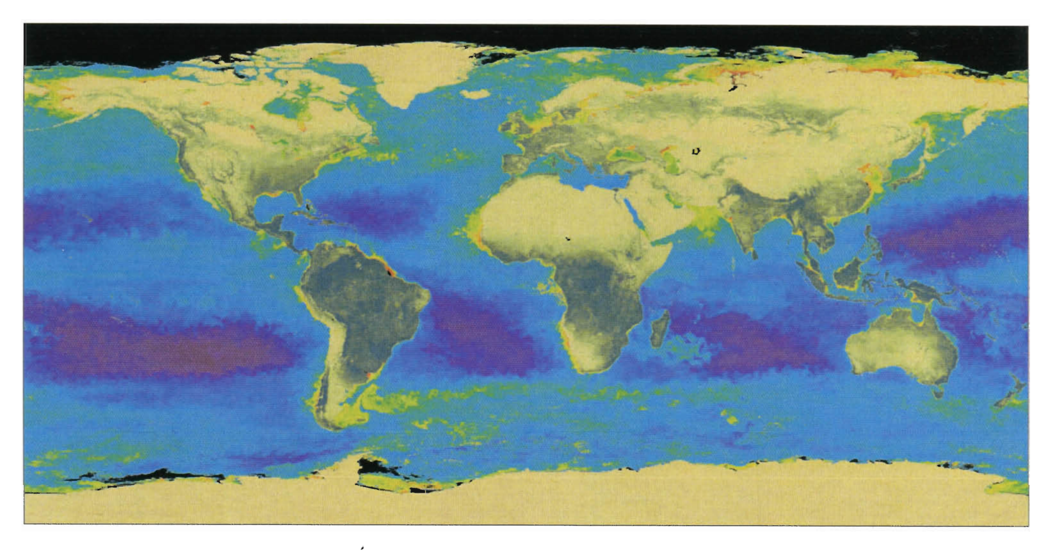


FIG. 10*. *Imagen de clorofila acuática y verdor terrestre obtenida a partir de datos Seawifs. (Fuente: http://visibleearth.nasa.gov/view_rec.php?id=1664).*

FIG. 11*. *Proceso de formación de las composiciones coloreadas.*

FIG. 12*. *Diversas composiciones en color sobre la imagen Madrid02.*

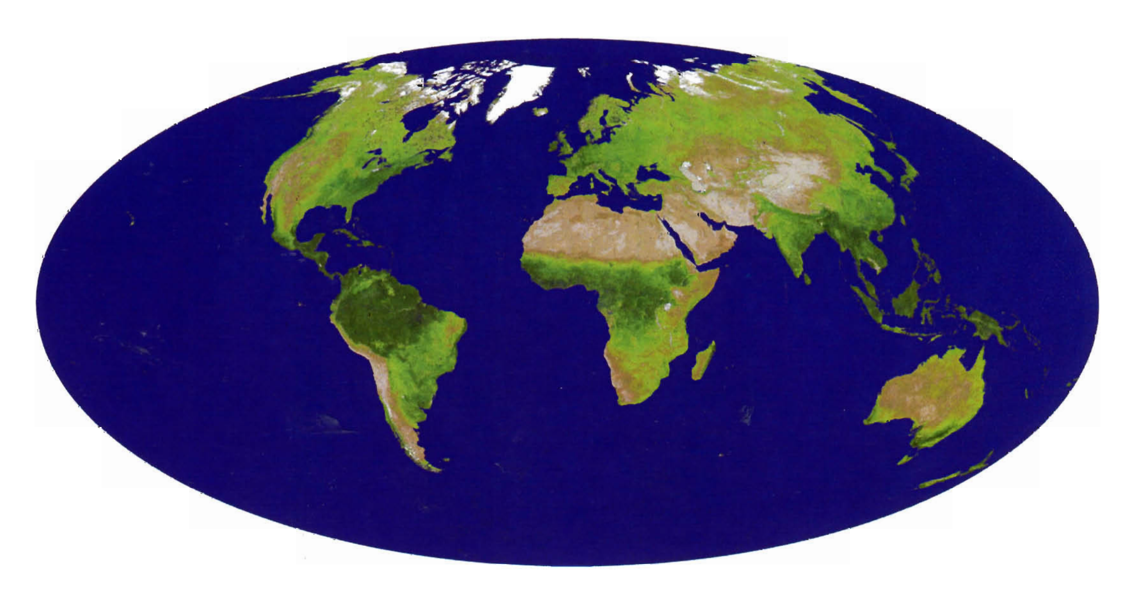


FIG. 13*. *Imagen global del EVI a partir de datos MODIS (Fuente: http://visibleearth.nasa.gov/).*

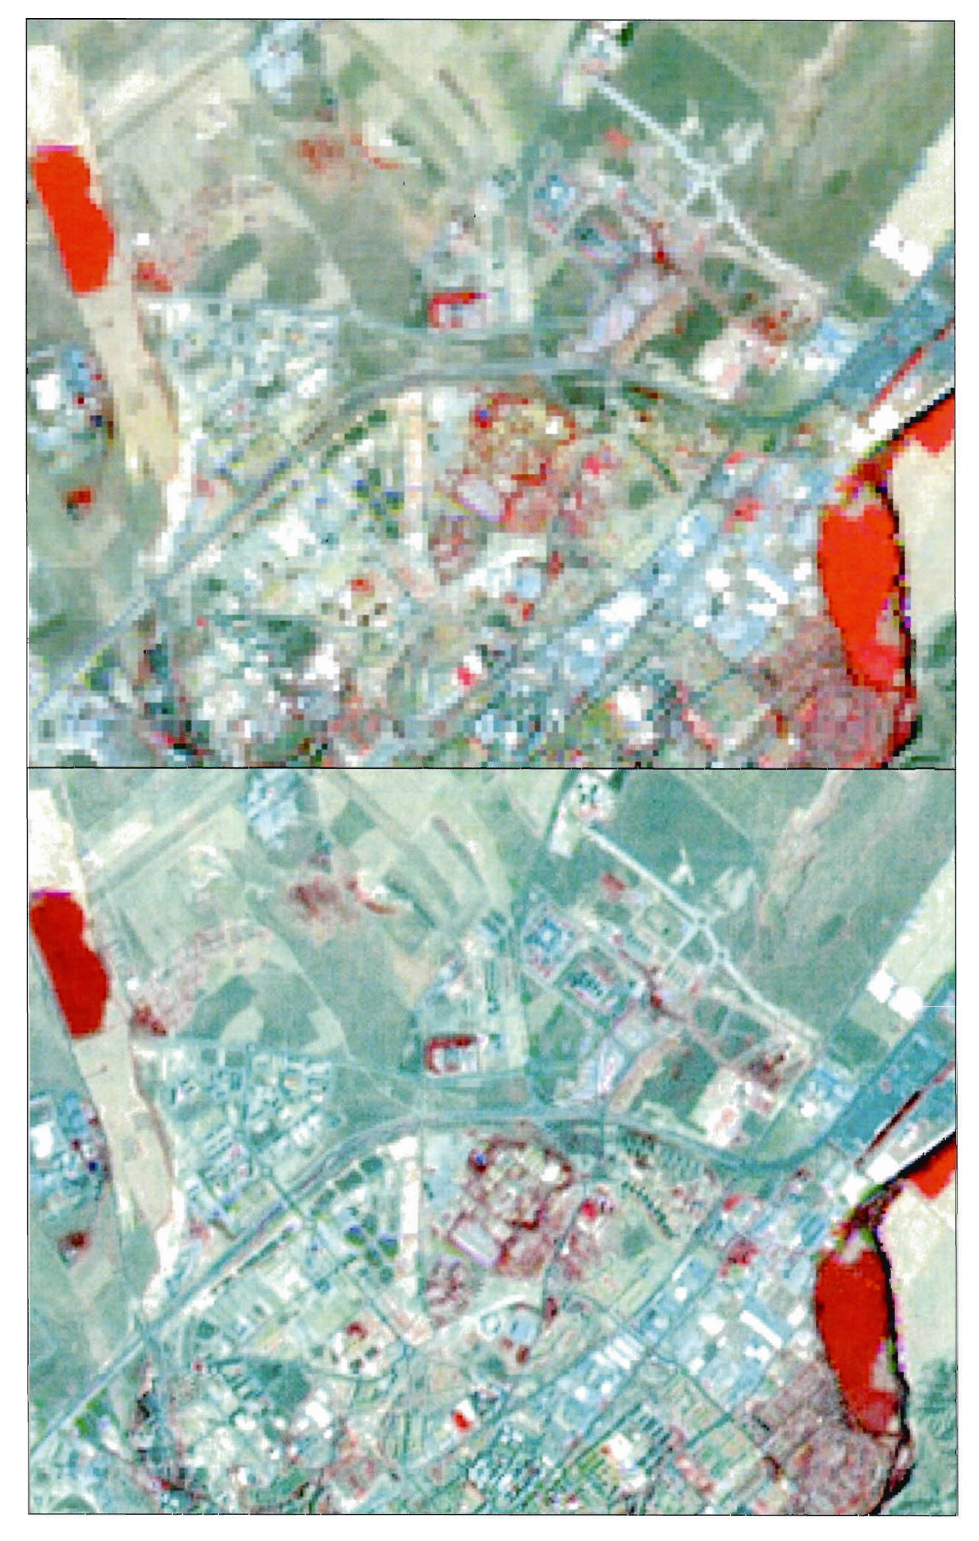


FIG. 14*. *Fusión del canal pancromático ETM y una composición en color 4/5/3 sobre una imagen de Alcalá de Henares: original (arriba), resultado de la fusión (abajo).*

FIG. 15*. *Clasificación supervisada de máxima probabilidad sobre la imagen Torrel00: (1) Agua; (2) Urbano; (3) Pinar; (4) Pastizal; (5) Matorral-Encinar; (6) Suelo descubierto (7) Cultivos.*

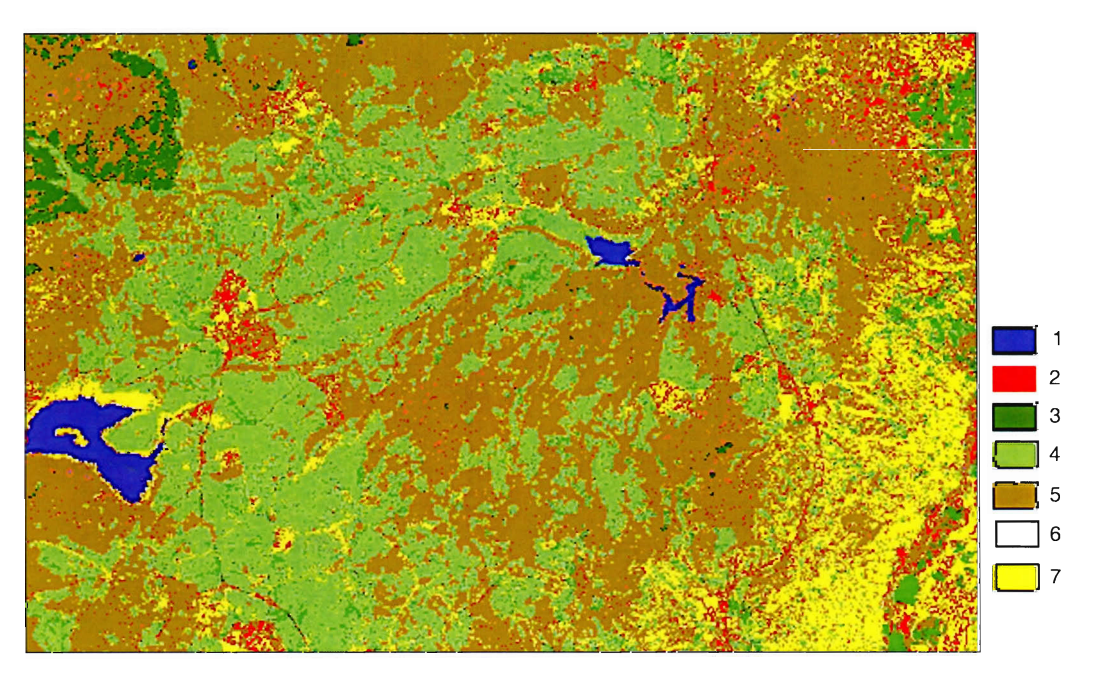


FIG. 16*. *Clasificación supervisada por redes neuronales sobre la imagen Torrel00 (la clave de color es igual a la figura anterior).*

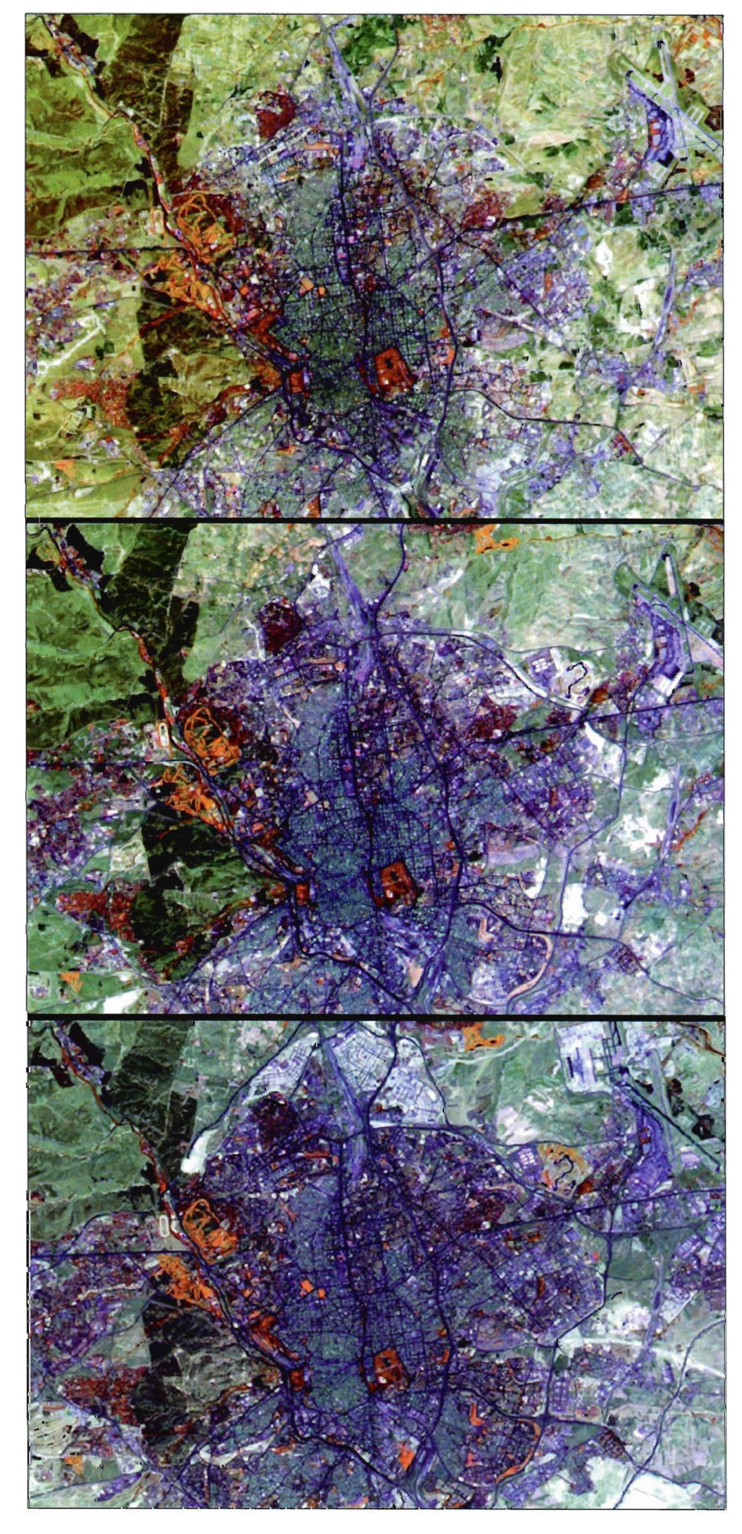


FIG. 17*. *Cambios en la ciudad de Madrid a partir del análisis temporal de imágenes Landsat-TM. De arriba abajo, 1984, 1992 y 2002.*

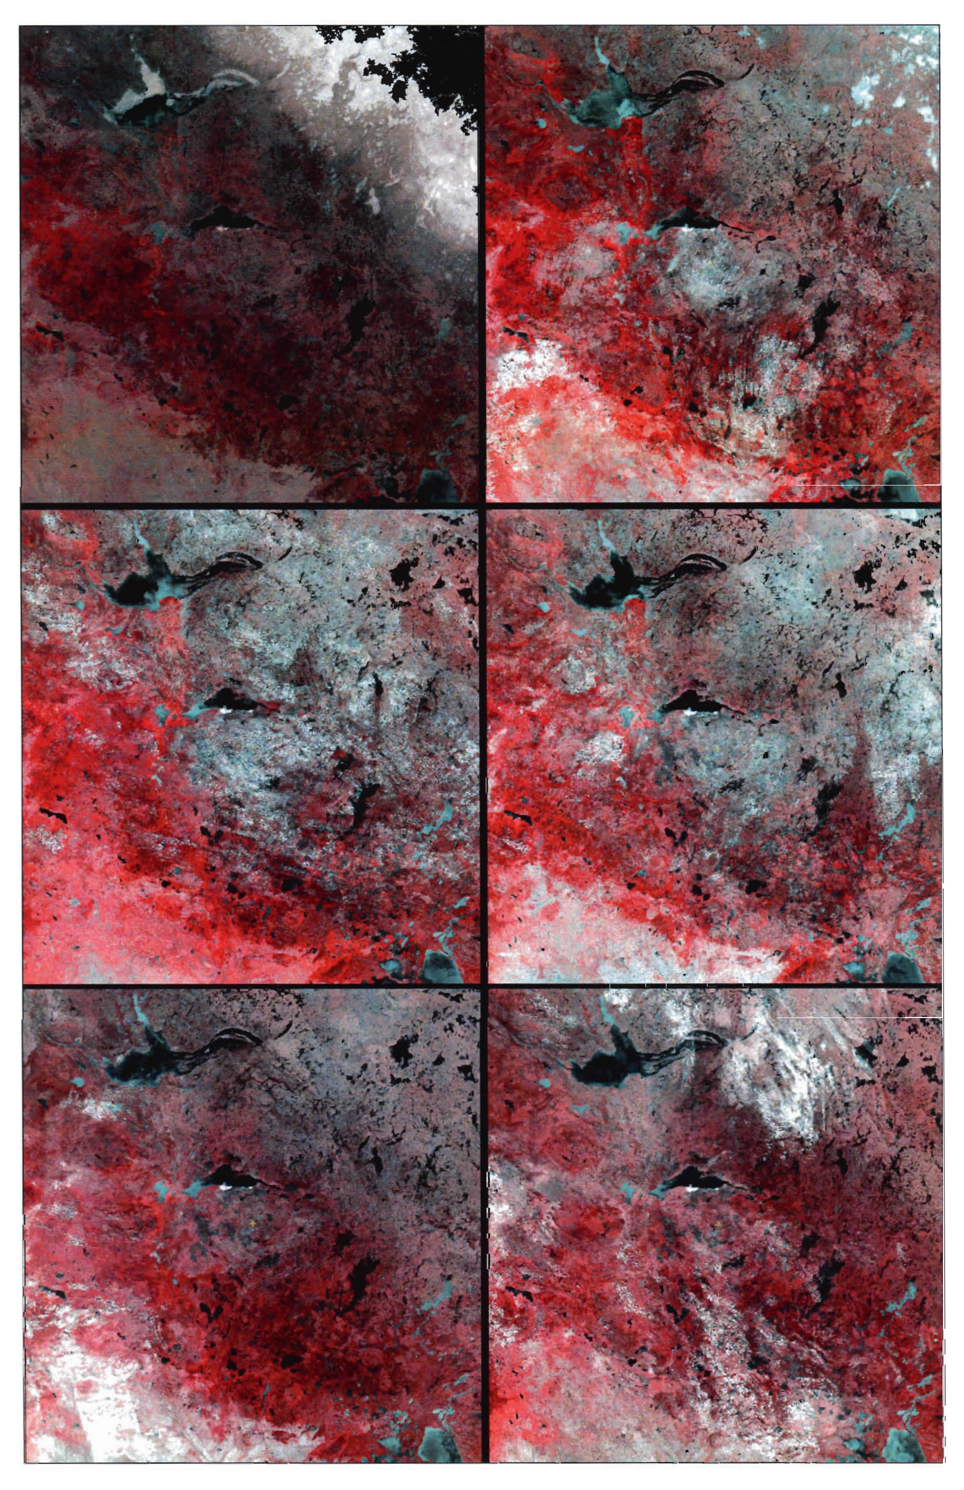


FIG. 18*. *Imágenes AVHRR de un amplio sector del norte de Canadá, comprendido entre las provincias de Alberta, Saskatchewan, Manitota y Northwestern Territories. Aparece una secuencia de imágenes adquiridas en 2006 por el NOAA-18. De arriba a abajo y de izquierda a derecha: inicios de mayo, junio, julio, agosto, septiembre y fines de septiembre.*

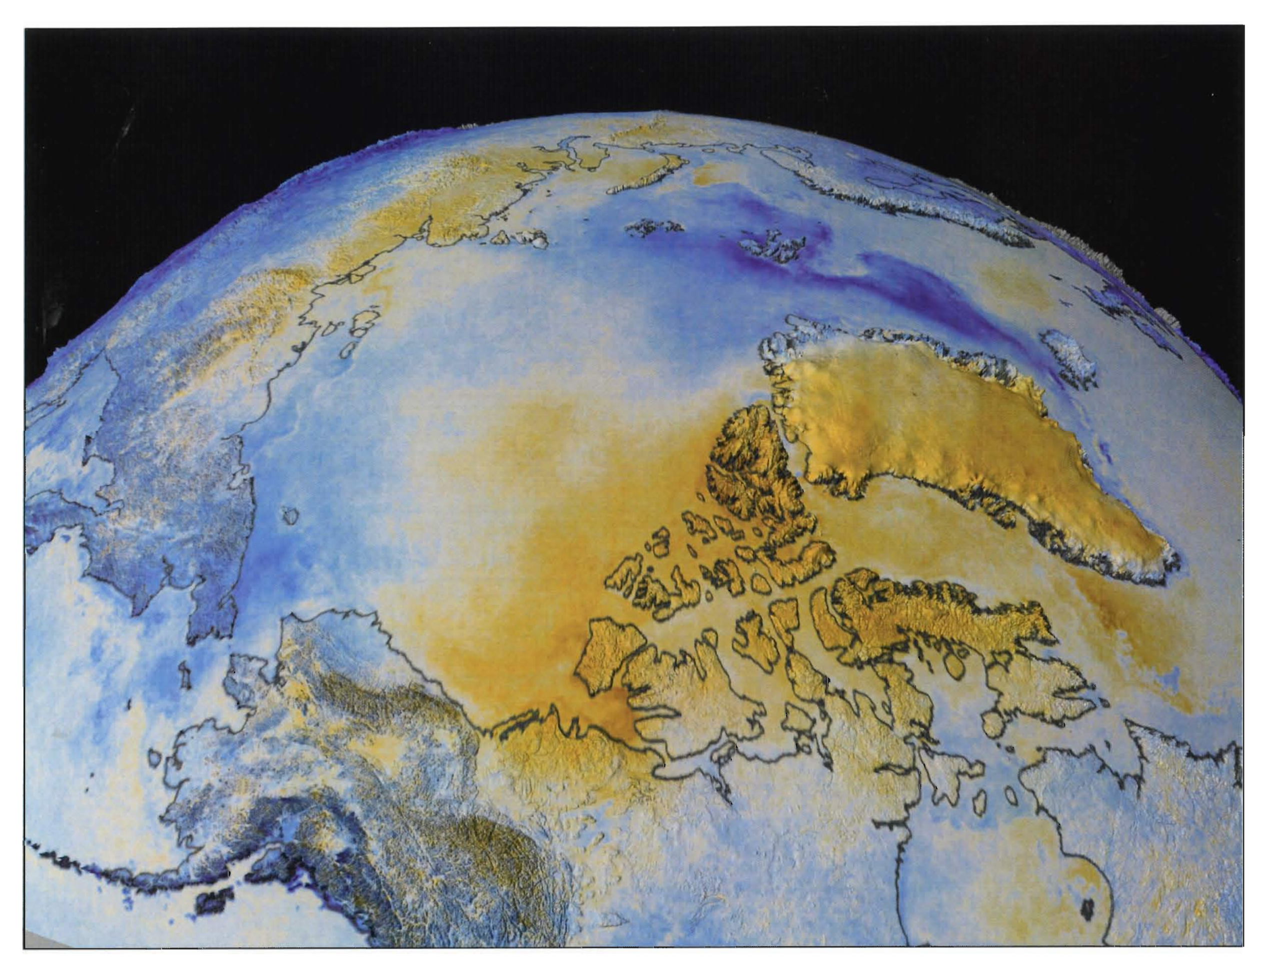


FIG. 19*. *Anomalías térmicas en el Ártico entre 1982 y 2002 (tonos rojos indican calentamiento y azules enfriamiento, blancos no cambio). Fuente: http://visibleearth.nasa.gov/*

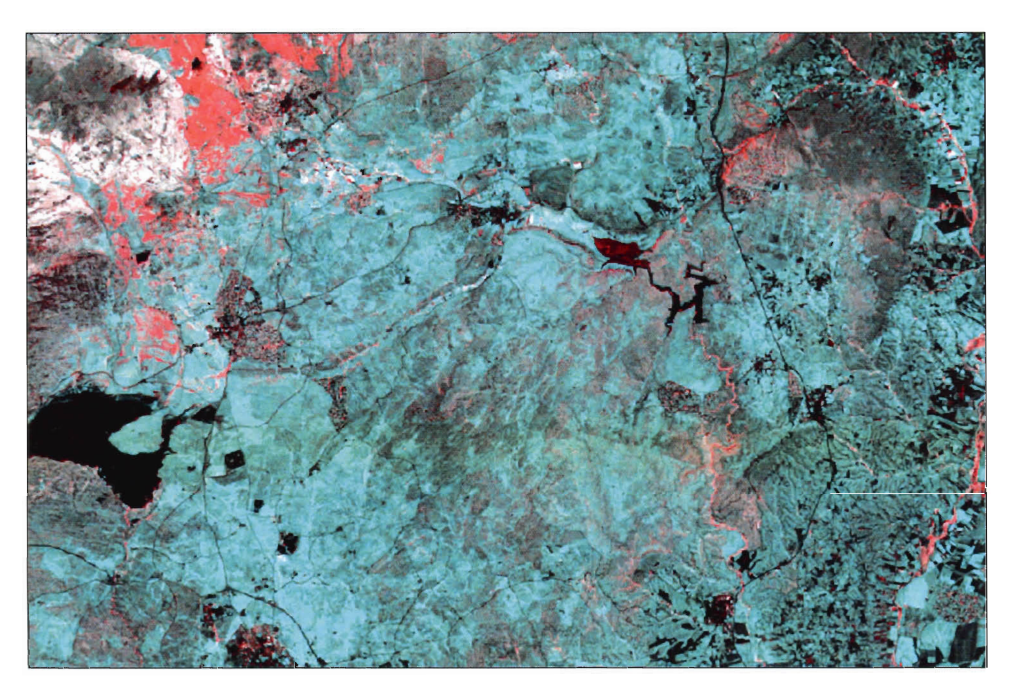


FIG. 20*. *Composiciones en color multitemporales a partir del NDVI de la imagen Torrel00. Rojo, verano de 1999; azul y verde, primavera de 2000.*

FIG. 21*. *Efecto de la resolución espacial sobre el patrón espacial de imágenes. Imágenes Landsat-TM (arriba) y NOAA-AVHRR (abajo), tomadas antes y después del incendio de Buñol (agosto de 1991).*

CAPÍTULO 6

ANÁLISIS DIGITAL DE IMÁGENES: CORRECCIONES Y REALCES

«La soledad no es estar solo, sino vivir con ausencia de significado.»

L. GIUSSANI, *El sentido religioso*

1. La matriz de datos en una imagen digital

Cada vez son menores las diferencias entre una imagen de satélite y una fotografía, gracias a la generalización de la fotografía digital, puesto que ambas se registran en formato numérico. Previamente, las cámaras almacenaban analógicamente la radiancia procedente de los objetos observados, sobre una película sensible a la luz. Los tonos de gris resultantes procedían del distinto nivel de exposición detectado. En un sistema digital, la radiancia recibida por el sensor se convierte directamente a un valor numérico y se almacena sobre un soporte magnético, como cualquier otra información digital. Esta conversión se realiza controladamente, gracias a una calibración precisa del sensor. Dicho valor numérico se puede invertir posteriormente para obtener la radiancia (fig. 6.1).

En una imagen digital, el territorio observado se divide en una serie de parcelas, habitualmente cuadradas, que corresponden al área instantánea observada en cada momento por el sensor. Estas parcelas constituyen la unidad mínima de información en la imagen y se denominan píxeles (del inglés *picture element*, elemento pictórico). En términos sencillos, podemos identificar un píxel como cada uno de los pequeños cuadrados que forman una imagen, visibles cuando se amplía (figura 6.2). El valor numérico que codifica cada píxel se denominará, de ahora en adelante, nivel digital (ND). Este nombre se justifica por tratarse de un valor numérico, no analógico, pero que puede fácilmente traducirse a una intensidad visual o, si se prefiere, a un nivel de gris, mediante cualquier convertidor digital-analógico (un monitor de visualización, por ejemplo). Cuando se visualiza un píxel, la intensidad de gris o de color con la que aparece en el monitor depende de su ND; la relación entre ambos puede modificarse a voluntad del intérprete como veremos más adelante (6.5.1). En ese sentido, conviene distinguir el ND de cada píxel adquirido por el sensor de

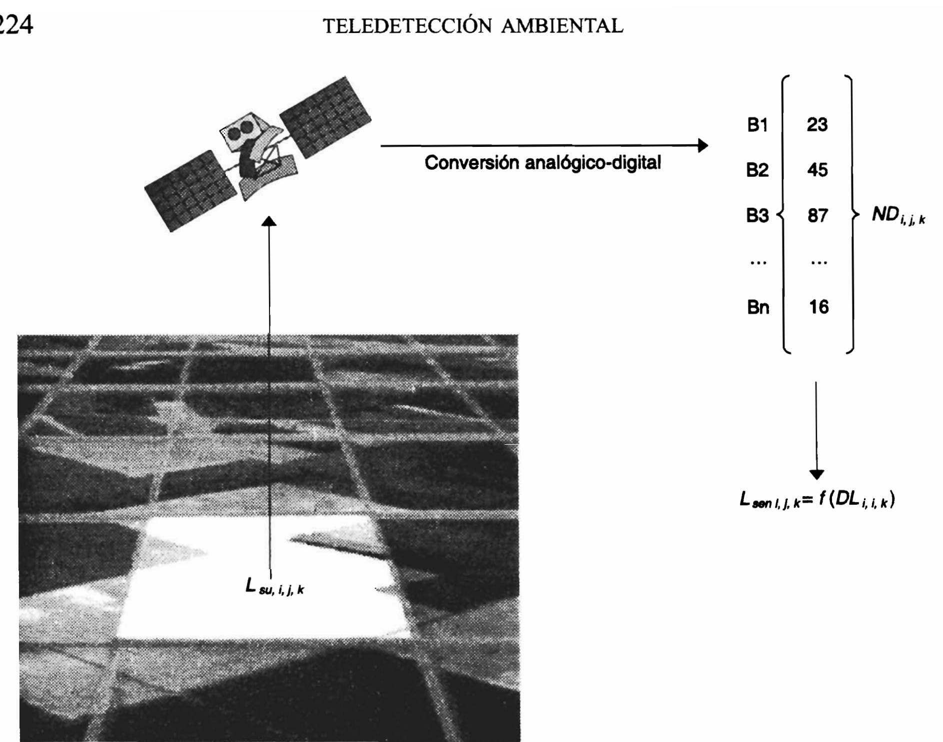
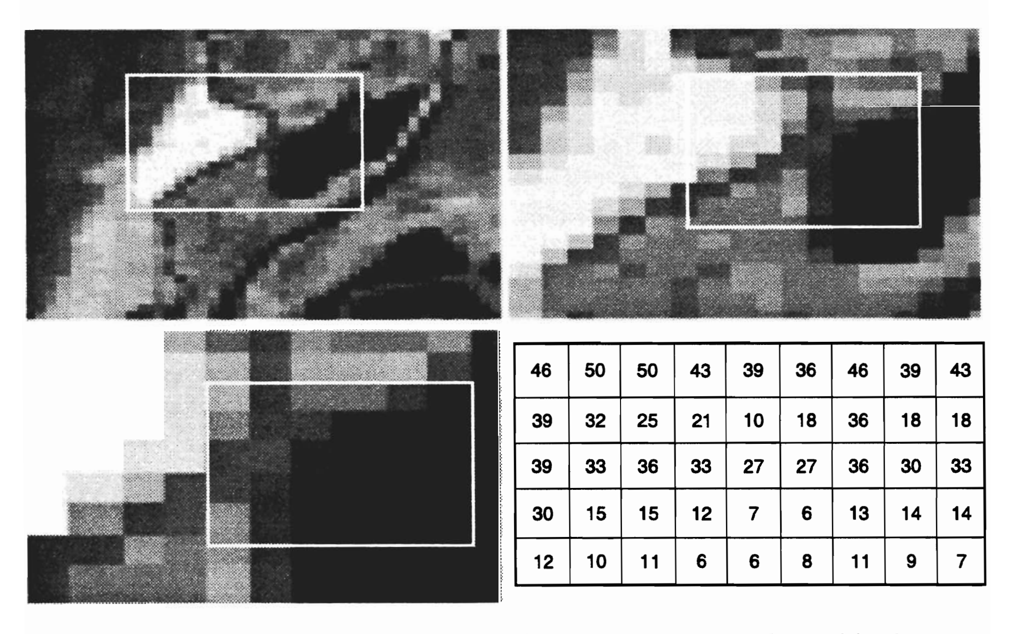


FIG. 6.1. *Diagrama que ilustra el proceso de adquisición de una imagen digital.*



46	50	50	43	39	36	46	39	43
39	32	25	21	10	18	36	18	18
39	33	36	33	27	27	36	30	33
30	15	15	12	7	6	13	14	14
12	10	11	6	6	8	11	9	7

FIG. 6.2. *Una imagen digital está formada por elementos pictóricos (píxeles) codificados por un valor numérico.*

su nivel visual (NV), que corresponde a la intensidad de gris o color con el que se visualiza ese píxel en el monitor. Normalmente, los NV son efímeros, ya que sólo se utilizan para operaciones de realce e interpretación visual de la imagen, mientras los ND forman la base para las operaciones de interpretación digital, especialmente cuando se intenta relacionar la información adquirida por el sensor con algún parámetro físico, como por ejemplo la reflectividad o temperatura.

El ND se conoce con distintos nombres en la bibliografía anglosajona: *Digital Number* (Lillesand y Kiefer, 2000), *Pixel Value* (Hord, 1986; Mather, 1998), *Brightness Value* (Jensen, 1996), *Grey Level* (Schowengerdt, 1983), o *Digital Count* (Richards, 1993). En nuestro idioma, nos parece más apropiado el término nivel digital (ND) para expresar mejor su significado, por cuanto se trata de un valor digital con un claro contenido pictórico relacionado con su nivel de gris. En resumen, la unidad mínima de información en una imagen digital se denomina píxel, definido por un número entero, ND, que puede convertirse en una intensidad luminosa o nivel de gris.

Teniendo presente estas ideas, la organización de los datos en una imagen digital puede esquematizarse en la figura 6.3. Como vemos, se trata de una matriz numérica de tres dimensiones. Las dos primeras corresponden a la posición geográfica (absoluta o relativa) de la imagen, mientras la tercera indica su dimensión espectral. La orientación Norte-Sur se obtiene variando las filas de la matriz, que normalmente reciben el nombre de líneas *(row, line)*, mientras el recorrido en el senti-

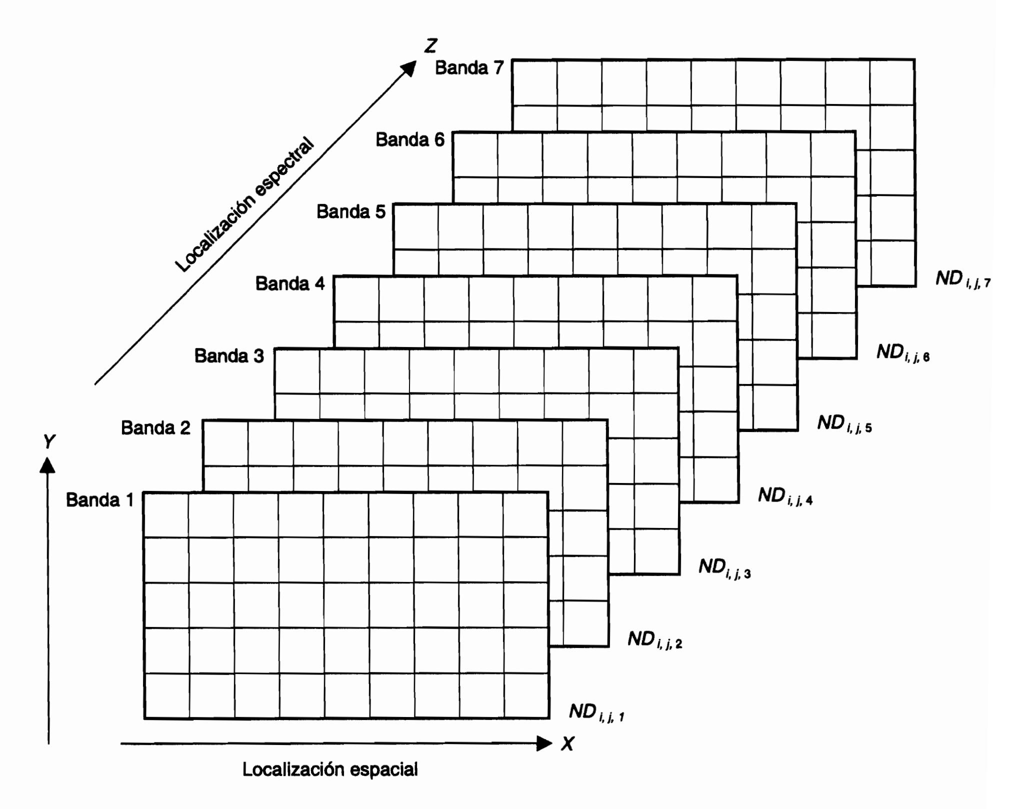


FIG. 6.3. *Organización de datos en una imagen digital.*

do de las columnas *(column)* indica la disposición Oeste-Este de la imagen. En esta matriz, el origen de coordenadas se sitúa en la esquina superior-izquierda (línea 1, columna 1), en lugar del borde inferior-izquierdo, como ocurre en cualquier eje cartesiano. Esto es debido a la secuencia de adquisición de imágenes, de norte a sur, de acuerdo a la traza del satélite. La tercera dimensión corresponde a las bandas espectrales del sensor: 36 para el MODIS, 7 para el ETM+, o 5 para el AVHRR.

Considerando ese carácter matricial de cualquier imagen son más fácilmente comprensibles las posteriores transformaciones aplicadas sobre ella. Éstas son, en muchos casos, operaciones estadísticas comunes a otras matrices numéricas, mientras en otros los son más específicas de la interpretación de datos de satélite. Por ejemplo, en una imagen digital podemos calcular medidas de tendencia central y dispersión (media y desviación típica en cada una de las bandas), cambiar su orientación geométrica (rotación de la matriz), realizar combinaciones aritméticas entre bandas (p. ej., cocientes), sintetizar varias bandas reduciendo la información redundante (componentes principales), o discriminar grupos de ND homogéneos dentro de la matriz (clasificación).

Como es lógico, el análisis digital de imágenes (ADI) se apoya en equipos informáticos adaptados a esta aplicación. Por ello, se inicia este capítulo con un repaso de las características y componentes de este tipo de equipos, que van a marcar el rango de posibilidades que se abra, en última instancia, al usuario. Además, se ha introducido un epígrafe previo, dedicado a la estructura de almacenamiento de datos en estas imágenes, con objeto de introducir al lector en el trabajo con este tipo de información numérica.

2. Soporte y organización de la imagen

Cualquier tratamiento digital aplicado a las imágenes, requiere que previamente éstas sean introducidas en un sistema informático; dicho de otro modo, que las imágenes sean accesibles al ordenador. Esto depende de los soportes y formatos en los que se ofrecen los ND que definen los píxeles de la imagen.

2.1. Soporte físico de una imagen

Hasta los años ochenta, las imágenes de satélite se distribuían de modo casi exclusivo en cintas magnéticas compatibles (CCT). Se trataba del soporte más estándar para almacenar un volumen considerable de información. Habitualmente, las cintas tenían 9 pistas *(tracks)*, con una longitud de 2.400 a 3.600 pies. Los principales problemas que planteaba una CCT eran su acceso secuencial, que ralentizaba la lectura de los datos, el alto coste de los equipos lectores y su escasa densidad de almacenamiento frente a las tecnologías actualmente disponibles, por lo que hoy sólo se utilizan para los archivos históricos.

Actualmente las imágenes se distribuyen principalmente en soporte óptico (CD o DVD), aunque cada vez es más común hacerlo a través de internet, utilizando los protocolos estándar de transferencia de archivos (FTP).

2.2. Formatos de grabación

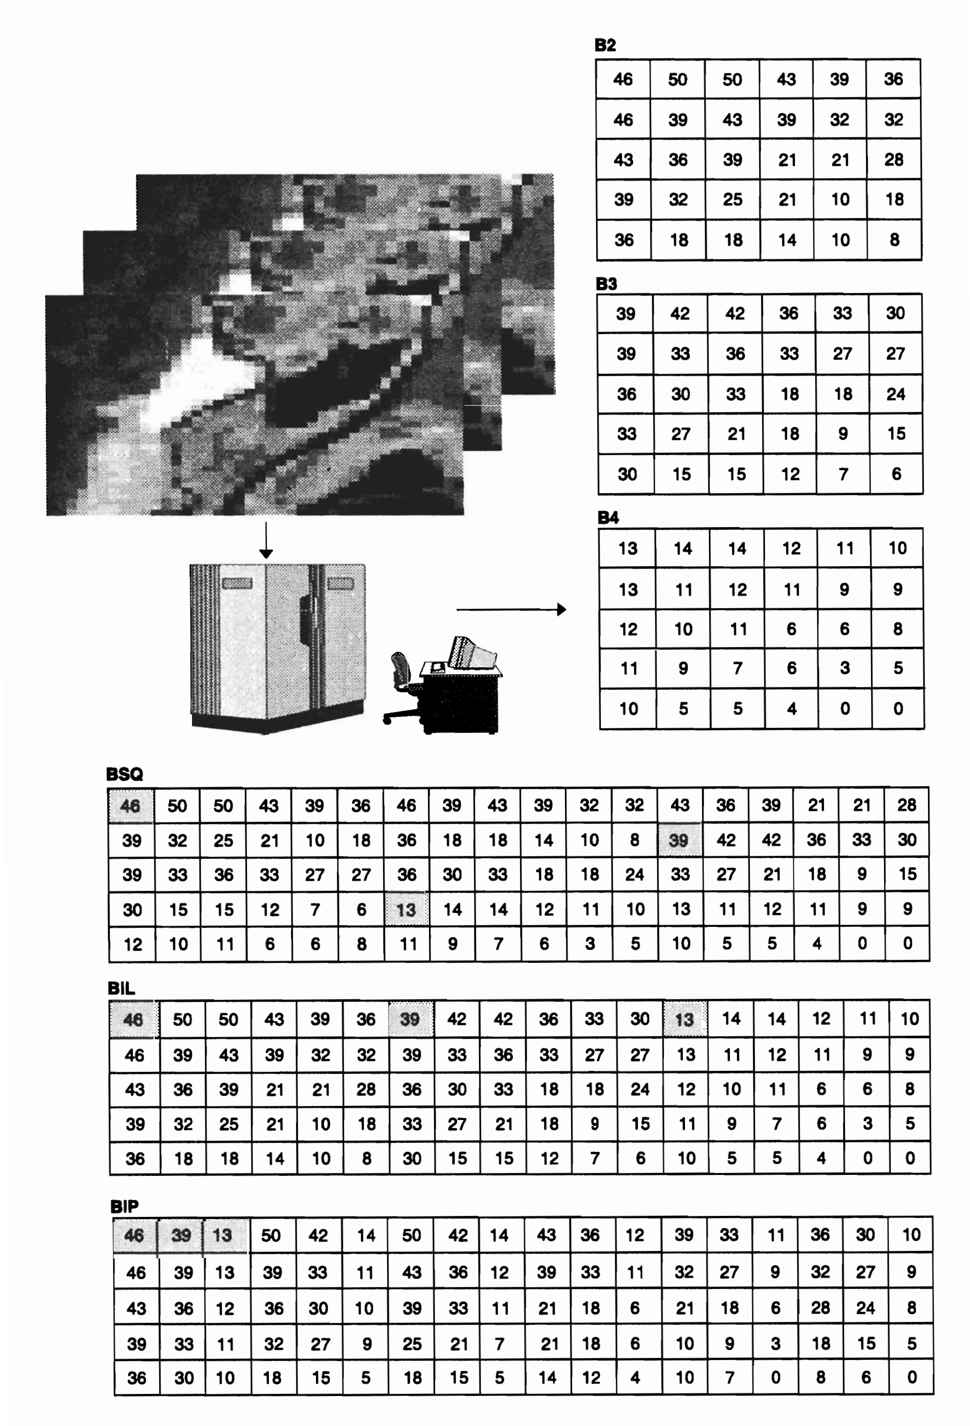
Independientemente del soporte físico de la imagen, es necesario conocer el formato de grabación de los datos, de cara a poder reconstruir posteriormente la información detectada por el sensor. En este sentido, conviene considerar la codificación aplicada y la organización lógica de los datos.

En lo que se refiere al primer punto, los ND de la imagen se graban en código binario (un bit indica una posición binaria, 0 o 1). Tradicionalmente, los sensores han codificado los ND en grupos de 8 bits. Por ello, cada píxel se define por un byte, lo que equivale a un rango de 256 niveles (2^8, de 0 a 255). Éste es también el rango admitido por la práctica totalidad de los equipos de tratamiento digital, por lo que el acceso a las imágenes se simplifica notablemente. En el caso de algunos sensores, como el NOAA-AVHRR, IKONOS, MODIS o las imágenes RADAR, la información se codifica en un rango más amplio (10, 12 o 16 bits), por lo que se requiere una labor previa de compresión de datos para poder visualizar la información en pantalla (6.5.1).

Las imágenes digitales se organizan en una serie de archivos *(files)*, cada uno de los cuales se descompone en registros *(records)*. Normalmente cada imagen incluye un archivo de cabecera *(header file)*, en donde se almacena el formato con el que están grabados los ND que la componen, así como sus condiciones de adquisición (tipo de sensor, localización de la escena, día, elevación y acimut solar, etc.), y, en su caso, el tipo de correcciones aplicadas por la estación receptora. Los registros son de longitud variable, de acuerdo al tipo de archivo y a la organización de los datos en la imagen.

La distribución de los archivos en una escena está en estrecha relación con el formato en que se graban los ND de la imagen. Los tres formatos más habituales son (fig. 6.4):

1. Bandas secuenciales (*Band Sequential*, BSQ). Implica que los ND de cada banda se disponen uno a continuación del otro hasta completar todos los píxeles que la forman. Tras ellos, se sitúan los ND de la siguiente banda y así sucesivamente hasta completar todas las bandas espectrales de la imagen. Normalmente, entre banda y banda se inserta un archivo de cola y otro de cabecera, con objeto de identificar la región del espectro sobre la que se está recogiendo información.
2. Bandas intercaladas por línea (*Band Interleaved by Line*, BIL). En este caso, los ND se organizan por líneas en lugar de por bandas, disponiéndose consecutivamente los correspondientes a todas las bandas, para cada línea, antes de comenzar la línea siguiente. En definitiva, tras los ND de la línea 1, banda 1, se sitúan los correspondientes a la línea 1, banda 2, para luego continuar los de la banda 3, 4, etc., hasta completar el número total de bandas. Tras la primera línea de la última banda se sitúa la segunda línea de la banda 1, de la banda 2, y así sucesivamente.
3. Bandas intercaladas por píxel (*Band Interleaved by Pixel*, BIP). En lugar de alternarse los ND en cada línea, se alternan en cada píxel. Así, tras el ND correspondiente al píxel de la línea 1, columna 1, banda 1, aparece el correspondiente a la línea 1, columna 1, banda 2, seguido del adquirido para la línea 1, columna 1, banda 3, etc. Este formato es, hoy por hoy, poco frecuente, ya que fue ideado para agi-



B2

46	50	50	43	39	36
46	39	43	39	32	32
43	36	39	21	21	28
39	32	25	21	10	18
36	18	18	14	10	8

B3

39	42	42	36	33	30
39	33	36	33	27	27
36	30	33	18	18	24
33	27	21	18	9	15
30	15	15	12	7	6

B4

13	14	14	12	11	10
13	11	12	11	9	9
12	10	11	6	6	8
11	9	7	6	3	5
10	5	5	4	0	0

BSQ

46	50	50	43	39	36	46	39	43	39	32	32	43	36	39	21	21	28
39	32	25	21	10	18	36	18	18	14	10	8	39	42	42	36	33	30
39	33	36	33	27	27	36	30	33	18	18	24	33	27	21	18	9	15
30	15	15	12	7	6	13	14	14	12	11	10	13	11	12	11	9	9
12	10	11	6	6	8	11	9	7	6	3	5	10	5	5	4	0	0

BIL

46	50	50	43	39	36	39	42	42	36	33	30	13	14	14	12	11	10
46	39	43	39	32	32	39	33	36	33	27	27	13	11	12	11	9	9
43	36	39	21	21	28	36	30	33	18	18	24	12	10	11	6	6	8
39	32	25	21	10	18	33	27	21	18	9	15	11	9	7	6	3	5
36	18	18	14	10	8	30	15	15	12	7	6	10	5	5	4	0	0

BIP

46	39	13	50	42	14	50	42	14	43	36	12	39	33	11	36	30	10
46	39	13	39	33	11	43	36	12	39	33	11	32	27	9	32	27	9
43	36	12	36	30	10	39	33	11	21	18	6	21	18	6	28	24	8
39	33	11	32	27	9	25	21	7	21	18	6	10	9	3	18	15	5
36	30	10	18	15	5	18	15	5	14	12	4	10	7	0	8	6	0

FIG. 6.4. *Formatos de grabación en una imagen digital: BSQ, bandas secuenciales; BIL, bandas intercaladas por línea; BIP, bandas intercaladas por píxel. Los píxeles en gris indican dónde comienza una nueva banda en cada uno de los tres formatos.*

lizar la clasificación de sub-imágenes, cuando se empleaban equipos de escasa memoria. Este formato se aplicó en los años ochenta a la distribución de imágenes en disquetes de 8 pulgadas, para alimentar los primeros equipos diseñados sobre microordenadores, pero ha quedado bastante en desuso.

Junto a estos formatos tradicionales, en los últimos años se han extendido mucho otros que intentan simplificar la lectura de archivos de múltiples bandas o hacer más abierto el acceso a archivos de gran volumen. Un ejemplo de los primeros sería el archivo HDF *(Hierarchical Data Format)* que permite almacenar imágenes ráster de distinta resolución espacial o tablas en un formato compacto, de fácil lectura y con sus propios metadatos. También se están difundiendo bastante otros formatos para información geográfica, como el GeoTIFF que es una imagen TIFF estandar pero que permite insertar metadatos geográficos, lo que facilita notablemente su acceso por programas genéricos de análisis de imágenes. Se está utilizando bastante para difundir imágenes georreferenciadas a través de Internet. Tanto el GeoTIFF como el HDF son formatos de dominio público, por lo que son accesibles por múltiples aplicaciones. También se está empleando mucho en los últimos años el formato KML *(Keyhole Markup Language)*, que es el empleado por Google Earth y Google Maps como lenguaje estándar para visualización de archivos gráficos en internet.

3. Equipos de análisis digital de imágenes

Si en todos los capítulos de este libro resulta muy complejo mantener actualizado el material que se comenta, la tarea resulta especialmente complicada cuando nos referimos a los componentes físicos y lógicos de un equipo de ADI, ya que la dinámica del mercado resulta realmente vertiginosa. La división que realizamos en las pasadas ediciones entre equipos básicos y avanzados sobre ordenador personal, por un lado, y sobre estación de trabajo, por otro, se ha desvanecido bastante, gracias al notable crecimiento de las capacidades de los equipos disponibles. Los avances en los sistemas operativos también han supuesto una creciente convergencia para los equipos de sobremesa, ya sean los basados en procesadores Intel, tradicionalmente usados para ordenadores personales, ya en los utilizados en las estaciones de trabajo, especialmente con la notable popularidad del Linux, que permite utilizar programas diseñados para estaciones de trabajo sobre ordenadores personales.

Para abordar convenientemente las principales operaciones del ADI, se requieren, como en cualquier otra aplicación informática, una serie de componentes físicos y lógicos. Entre los primeros (fig. 6.5) hay que analizar las unidades de entrada (hoy resultan imprescindibles sólo el teclado y el ratón electrónico o similar), las de almacenamiento y proceso (memorias internas y externas) y las de salida (principalmente el monitor, aunque también una impresora en color). En este momento, los equipos más estándar en informática personal cuentan con memorias internas de 2 Gb, velocidades de proceso superiores a 2,2 GHz, y almacenamiento en disco por encima de 250 Gb. Los equipos gráficos más estándar están ya siendo los monito-

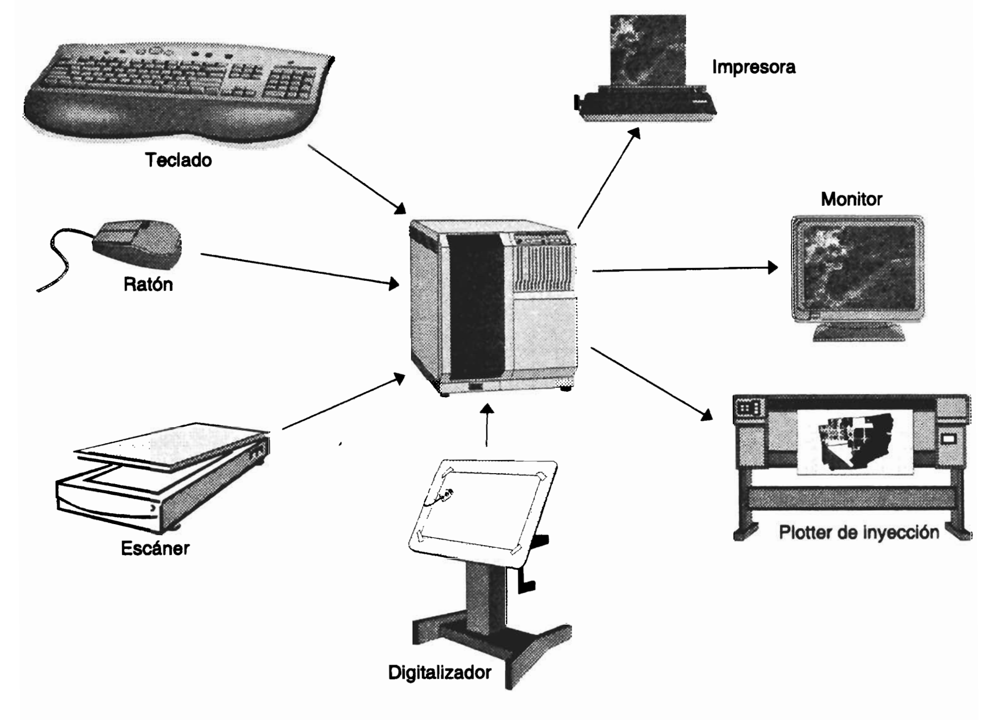


FIG. 6.5. *Componentes de un equipo de tratamiento digital de imágenes.*

res TFT de 19 pulgadas. Entre los periféricos de salida, conviene citar las impresoras de inyección de tinta, que en este momento siguen siendo el estándar en impresión a color, aunque las láser y de sublimación térmica han descendido mucho de precios y tienen buena relación entre calidad y coste de los consumibles.

En lo que se refiere a los componentes lógicos *(software)*, suelen distinguirse dos categorías básicas: sistema operativo y programas de aplicación. Como antes comentamos, existe una clara convergencia en lo que se refiere a sistemas operativos. Actualmente podemos dar por desaparecidos algunos (como el VMS, muy utilizado en ordenadores de cierta potencia en los años setenta y ochenta, o el MS-DOS, el primer sistema que instaló IBM en sus ordenadores personales), dominando el mercado los basados en el entorno Windows (principalmente la versión XP y Vista) y las diversas versiones de UNIX (principalmente las basadas en entornos de ventanas, Xwindows, y Linux, para procesadores Intel). En los últimos años también se están desarrollando tecnologías para ejecutar programas en servidores remotos, que permiten acceder a recursos que no están disponibles en nuestro propio equipo.

Los programas de aplicación utilizan los recursos del sistema operativo para comunicarse con el ordenador. Como es bien sabido, el ordenador sólo es capaz de procesar caracteres binarios, por lo que toda instrucción que el usuario pretenda ejecutar ha de ser convertida a este código. Esta tediosa labor la ejecutan los compiladores, programas que convierten una serie de instrucciones más o menos cercanas al lenguaje humano en un código que entienda la máquina. Existen distintos compiladores para cada uno de los lenguajes de programación, y para los sistemas opera-

tivos más comunes. Entre los lenguajes más empleados en ADI cabe citar el C (con sus diversas variantes), FORTRAN, Pascal (más recientemente Delphi), Basic (más recientemente *Visual Basic*), IDL y APL.

Ahora bien, lo habitual no será que el usuario escriba sus propios programas, sino que utilice alguno de los muchos disponibles, tanto comerciales como de dominio público. Existe una variada oferta de programas de ADI que ofrecen las operaciones más comunes en este campo, por lo que el intérprete comúnmente sólo tendrá que diseñar sus propios programas cuando sea preciso atender una tarea muy particular, especialmente cuando se trata de una labor de investigación. Estos nuevos desarrollos se facilitan gracias a que casi todos los programas disponen de una cierta capacidad de programación. Puede tratarse de entornos de programación gráficos, que permitan al intérprete seleccionar y encadenar, en el orden que crea conveniente, distintas operaciones que brinda el propio sistema, o bien de librerías de programas, que el usuario pueda engarzar mediante algún lenguaje de programación estándar (Visual Basic, por ejemplo). Finalmente, podría también ofrecerse la posibilidad de enlazar el programa de ADI con rutinas diseñadas fuera del sistema, para realizar operaciones específicas no facilitadas de modo estándar. Por ejemplo, un modulo de clasificación externo al sistema, pero con el que éste pueda compartir formatos.

Las tendencias más recientes de los equipos de ADI insisten en el entorno amigable al usuario que viene observándose desde los años noventa, garantizan una buena conexión con bases de datos externas (amplia capacidad de exportación/importación de archivos), cuentan con mayor interrelación con los Sistemas de Información Geográfica (SIG, cap. 9), y facilitan entornos más abiertos. Entre los programas comerciales de ADI, los más conocidos siguen siendo ERDAS, PCI - Geomatics, ER-Mapper, Envi Idrisi y Miramon (aunque éstos dos últimos propiamente se consideran más como un SIG que como un programa ADI), mientras entre los de dominio público, disponibles habitualmente en internet, conviene citar el Multispec, diseñado en la Universidad de Purdue, el SPRING, producido por el Instituto Brasileño de Investigaciones Espaciales (INPE), y el GRASS, creado inicialmente por el cuerpo de ingenieros militares norteamericano.

Finalmente, conviene aclarar que no existe un criterio absoluto para elegir entre un sistema y otro. En otras palabras, para evaluar un equipo de ADI habrá que pensar en todo momento en la aplicación a la que se destina. Un usuario con interés en aplicaciones geológicas valorará la capacidad de visualización del equipo, así como las transformaciones y realces que ofrezca. Por el contrario, uno interesado en cartografía de la vegetación o de la cubierta del suelo, estará más atento a los algoritmos de clasificación que incorpora. Para uno y otro usuario, sin embargo, convendrá tener en cuenta algunas características generales:

— Rapidez de proceso, en función del lenguaje de programación y de la estructura de los algoritmos empleados. Convendrá anotar los tiempos empleados en realizar operaciones comunes, como sería filtrar o clasificar una ventana de la imagen.

— Diálogo con el usuario. La mayor parte de los equipos más recientes mejoran notablemente la facilidad de manejo, incorporando un sistema de menús y una serie de instrucciones de ayuda en directo al usuario. Convendrá tener en cuenta este aspecto de cara a obtener resultados en el menor tiempo posible.

— Capacidades de exportación/importación de archivos, tipo de formatos a los que accede para lectura o escritura, con especial interés en aquellos más estándares.

— Capacidades de programación. Lenguajes macros, librerías o lenguajes de programación disponibles.

4. Operaciones de utilidad general

Se inicia ahora el estudio de las operaciones más comunes en ADI, siempre en el contexto de las aplicaciones de la teledetección espacial.

A lo largo de éste y el siguiente capítulo utilizaremos principalmente una imagen adquirida por el sensor ETM+ del Landsat-7 el 15 de Marzo de 2000, que ya tuvimos ocasión de presentar en el tema 5 (fig. 5.19). La imagen corresponde a un sector situado al norte de la ciudad de Madrid, que incluye las poblaciones de Manzanares y Soto del Real, Guadalix, Miraflores de la Sierra y parte de Colmenar Viejo y Torrelaguna. Hemos elegido esta imagen por haberse adquirido con buenas condiciones de observación, sin cobertura nubosa, y en una zona bastante variada, tanto desde el punto de vista de la topografía, desde 2.000 m en el vértice NW de la zona, hasta los 700 m en el valle del Jarama, como de la ocupación por pinares, caducifolias, pastizales, zonas residenciales, cultivos, matorral, láminas de agua, etc. Además, contamos con imágenes de otras fechas de la misma zona, de cara a realizar comparaciones multitemporales. Elegir una sola imagen para ilustrar las diversas técnicas de análisis digital resulta un arma de doble filo. Por un lado, facilita al lector la comprensión de dicha técnica, al compararla con otras que ya ha visto o va a ver sobre la misma zona. Por otro, puede introducir una cierta monotonía, además de que, en algunos casos, la zona elegida no sea muy apropiada para esclarecer la técnica que se esté comentando. Finalmente, la decisión que hemos tomado es ecléctica: utilizaremos como base una sola imagen, pero se enriquecerá la interpretación con ejemplos de otras imágenes cuando nos parezca apropiado. En el anexo 5 se incluye una referencia más completa de todas las imágenes utilizadas.

Los procesos aplicados sobre esta imagen se basan en varios programas de ADI disponibles en nuestro departamento, aunque la mayor parte de las operaciones las hemos realizado con el programa *PCI Geomatics* empleado para esta edición del libro la versión 10.1. Todas las operaciones presentadas en este capítulo se pueden realizar prácticamente con cualquier otro software de ADI.

Se inicia el examen de las técnicas de ADI con procesos que hemos calificado de utilidad general, por cuanto pueden aplicarse a diversas finalidades y sirven de escalón intermedio para otras operaciones más específicas. Se incluyen en este apartado aquellas actividades que se relacionan con la manipulación de archivos, cálculo de estadísticas sobre la imagen y visualización.

4.1. Gestión de archivos

Cualquier sistema de ADI incluye una serie de utilidades generales que le permiten gestionar apropiadamente los archivos donde se alojan las imágenes, polígo-

nos auxiliares y tablas de color, así como las distintas transformaciones que sobre ellas se apliquen. Las más elementales son los comandos propios del sistema operativo, como copiar, cambiar el nombre o eliminar archivos.

Entre las más específicas del ADI, la primera en orden cronológico es la lectura de los datos originales. Esta operación implica contar con un programa que importe los datos de la imagen en el soporte y formato proporcionados por el organismo distribuidor de las mismas. Lo ideal es que permita leer la información almacenada en las cabeceras de cada archivo, con objeto de poder importar automáticamente los datos referentes al tamaño de la imagen, condiciones de adquisición y calibración del sensor (metadatos). También resulta muy útil que el programa nos ofrezca la opción de leer una pequeña ventana de la imagen (que incluya el área de interés), extrayendo los ND correspondientes a las bandas originales sobre las que se pretenda trabajar. Esa labor se facilita si el programa de lectura de imagen incorpora alguna rutina para la visualización del área designada, lo que permite una localización interactiva de las coordenadas inicial y final de esa ventana, agilizando bastante el proceso de búsqueda. Si no se conoce aproximadamente la localización de esa ventana en la imagen, resulta conveniente contar con alguna opción para leer la imagen con un factor de reducción, lo que permite visualizar una superficie mayor a la que admitiría la resolución de la pantalla. Esto implica, en definitiva, un muestreo sistemático de la imagen, eligiendo una columna y línea de cada n, siendo n el factor de reducción. Cuando se ha localizado el área de interés sobre esa zona más amplia, puede accederse a aquélla con la plena resolución de la imagen (píxel a píxel).

Una vez leídos los datos, el programa requiere generar una serie de campos para la documentación de la imagen, que le permitirán gestionar posteriormente su visualización y análisis. Para reconocer apropiadamente un archivo de imagen, cualquier programa necesita saber sus dimensiones (número de líneas y columnas), el número de bandas y número de bits por píxel, de otra manera no podrá reconstruir la estructura original de los datos. Además, si la imagen está georreferenciada, es preciso conocer los datos de la proyección, las coordenadas de sus vértices y el tamaño del píxel en x e y. Otra información relevante sería la concerniente a las estadísticas de la imagen (descriptivas, histogramas, etc.), y a las condiciones de adquisición.

En algunos programas esa documentación de la imagen se asocia permanentemente al archivo principal, ocupando los primeros bytes; en otros, se almacena en un archivo independiente, normalmente con el mismo nombre de la imagen original y otra extensión. Esta segunda opción facilitará normalmente la lectura de la imagen por otros programas, ya que el archivo sólo contendrá datos de imagen y no información auxiliar. También en función del programa de tratamiento elegido, los datos pueden almacenarse en formato BSQ o BIL. En el primer caso, cada banda ocupa un archivo distinto, mientras en el segundo todas las bandas se incluyen en el mismo. Esta segunda opción agiliza el cálculo cuando se trata de generar combinaciones entre bandas de la misma imagen, pero lo dificulta si se pretende relacionar información de dos imágenes. En el caso del programa PCI Geomatica, toda la información se graba en el mismo archivo, tanto las bandas detectadas por el sensor, como las estadísticas, documentación, vectores o anotaciones que realice posteriormente el intérprete (fig. 6.6). Esto permite un almacenamiento compacto, en donde

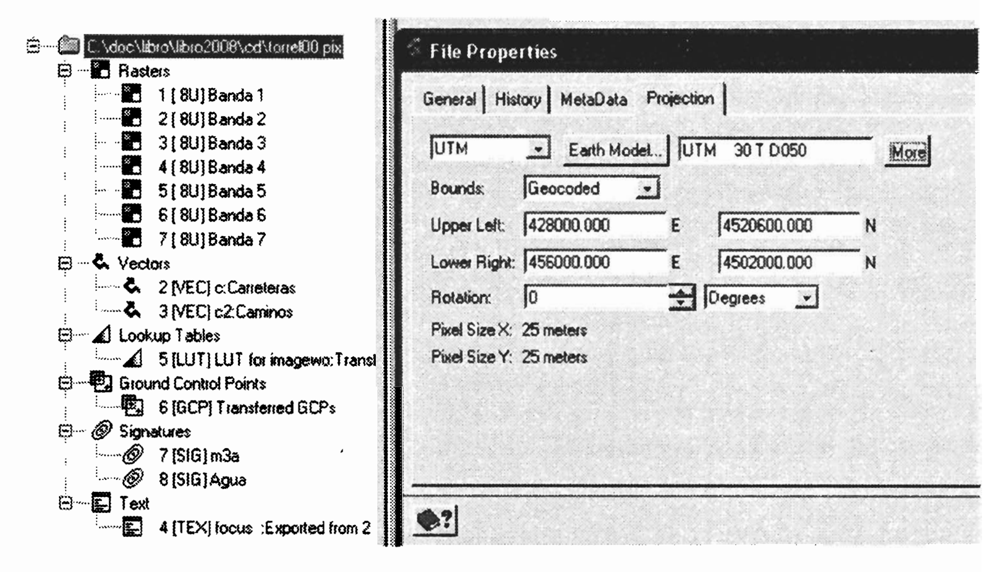


FIG. 6.6. *Panel descriptivo del archivo que incluye la imagen de ejemplo en el programa Geomatico.*

todo lo referente a una escena se encuentra disponible en una sola ubicación, pero tiene el problema de generar archivos que pueden llegar a ser muy grandes.

Otra utilidad de interés en ciertas aplicaciones es aislar un sector de la imagen, definido por un polígono irregular, de cara a aplicarle un tratamiento específico. La operación recibe también el nombre de máscara, y se utiliza con bastante asiduidad en el contexto de los SIG (por ejemplo, para obtener resultados referidos a una determinada unidad administrativa). El trabajo con sectores irregulares de la imagen implica los siguientes procesos:

1. Delimitar los límites del polígono deseado, con ayuda de un digitizador, cursor, o ratón electrónico.
2. Aislar todos los píxeles que se sitúen en el interior de dicho polígono de los que se encuentren fuera. Estos últimos pasarán a tener un ND igual a 0 y serían eliminados de posteriores tratamientos.

La figura 6.7 ilustra la realización de este proceso para la imagen Torre100. Se ha extraído un sector correspondiente al centro de la ventana, definido por la red local de carreteras. Tras digitizar el polígono se extrajeron los ND correspondientes a la banda 3 del interior de esa zona, eliminándose el resto.

4.2. UTILIDADES PARA LA VISUALIZACIÓN

La capacidad para la visualización de la imagen debe considerarse como una de las principales características de un equipo de ADI. Esa capacidad es dependiente del *hardware* disponible y de las herramientas que ofrece el sistema para «dialo-



FIG. 6.7. *Ejemplo de máscara aplicada a un sector de la imagen de Torrelaguna.*

gar» con el monitor gráfico. La relación, en este sentido, sería muy amplia, puesto que una de las tendencias de mayor desarrollo, en el momento presente, tiende precisamente a construir sistemas mucho más interactivos con el usuario.

En lo que se refiere al ámbito que nos ocupa, las utilidades de visualización más habituales son:

1. *Conversión digital-analógica de los ND almacenados en la imagen, lo que permite su representación en el monitor gráfico.* El proceso técnico aplicado puede estudiarse en otras publicaciones (Richards, 1993), apéndice F; (Muller, 1988*b*). Basta aquí indicar que supone convertir un valor numérico (el ND de cada píxel) en una señal analógica que se envía a un monitor para su representación visual. Con objeto de que la imagen visualizada se mantenga en el monitor, existe un dispositivo intermedio, denominado memoria gráfica o de refresco *(refresh buffer)*, que almacena temporalmente los ND visualizados hasta que se envíe una nueva imagen al monitor. A partir de esa memoria intermedia, se produce un barrido del tubo de imagen, a un ritmo de 25 ó 30 veces por segundo, suficientemente alto para que no pueda apreciarse por el ojo humano. Lo más habitual es que se cuente con tres memorias de refresco, una para cada uno de los tres colores elementales (RVA), gracias a lo que pueden visualizarse tres bandas simultáneamente.

2. *Obtención de coordenadas.* Con ayuda del digitizador o del ratón electrónico pueden conocerse las coordenadas de distintos puntos de interés, de cara a la corrección geométrica de la imagen (6.6.3) o a la caracterización espectral de distintas cubiertas. La localización se facilita por la ayuda de un cursor gráfico (fig. 6.8).

3. *Digitización de áreas sobre la imagen, realizada —al igual que en el caso anterior— con la ayuda de un cursor móvil.* Estas zonas pueden hacerse corresponder con áreas de entrenamiento para la clasificación (7.2.2), con elementos lineales para anotar los resultados (carreteras o ríos), o con sectores que pretenden aislarse de la imagen (máscaras). En similares términos cabe expresarse en lo que hace referencia a la inclusión de rótulos o simbología gráfica (encabezamientos, flechas de orientación, líneas, retícula U.T.M., etc.), de interés para la presentación cartográfica de los resultados (7.2.4).

4. *Cambios de escala, esta operación se dirige a ampliar o reducir la imagen visualizada para verla con mayor o menor detalle, respectivamente.* Este proceso se realiza en la memoria de refresco, por lo que se obtiene casi instantáneamente, facilitando la interactividad con el intérprete. Además de aumentar el tamaño del pí-

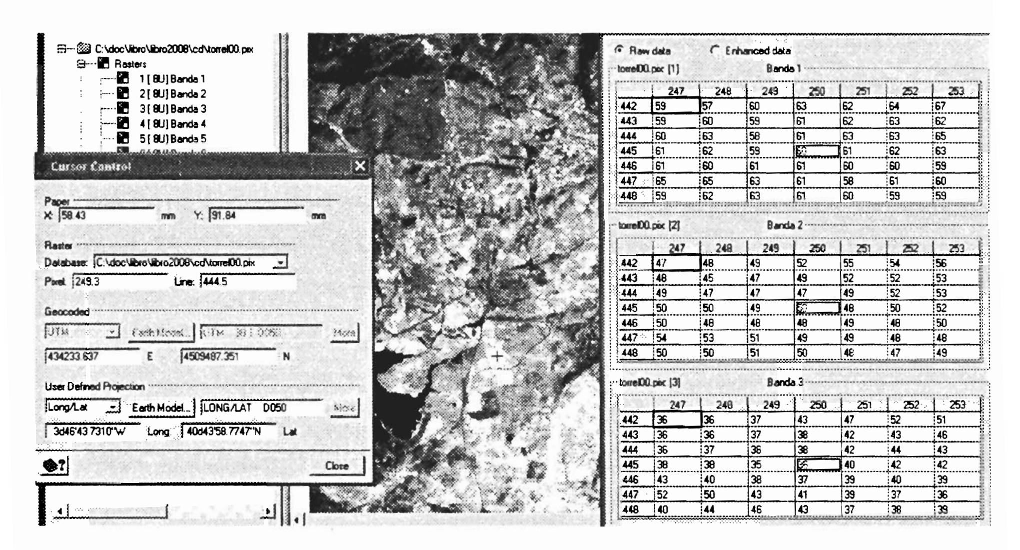


FIG. 6.8. *Extracción de información a partir de la posición del cursor: información geográfica (derecha), e información espectral (ND, izquierda).*

xel, el usuario puede desplazarse sobre la imagen a esa nueva escala *(pan, roll)*, facilitando notablemente la localización de zonas de interés. Una ampliación de mayor calidad visual puede lograrse mediante un *zoom* interpolado. Aquí, en lugar de una simple réplica de los ND originales, se crea una nueva matriz de tamaño equivalente al nivel de magnificación. En esta matriz se sitúan los ND originales, y se calculan los otros por interpolación lineal de estos valores. La impresión que causa sobre la pantalla es la de una imagen mucho más nítida, puesto que mantiene una mejor transición entre píxeles vecinos (fig. 6.9).



FIG. 6.9. *Comparación entre un* zoom *por expansión (izquierda) y por interpolación (derecha) sobre una ventana de la imagen Alcalá99.*

5. *Creación de archivos de visualización.* En muchas ocasiones resulta muy conveniente contar con una copia de la información almacenada en el monitor. Esto se consigue gracias a un programa auxiliar que salva la memoria de refresco en el disco, generando una nueva imagen que puede visualizarse posteriormente. Gracias a ello, pueden visualizarse un conjunto de imágenes y/o elementos gráficos asociados, sin necesidad de repetir todo el proceso que llevó a su creación. Conviene tener en cuenta, sin embargo, que en este caso la precisión de los datos depende de la resolución de la memoria gráfica. En ocasiones la imagen tendrá que comprimirse para que puedan visualizarse varias bandas simultáneamente, mientras con la creación de un archivo compuesto se mantiene la resolución original de los datos. Existen numerosos programas en el mercado que permiten capturar la información visualizada en pantalla (o una parte de ella), lo que resulta muy conveniente para fines didácticos.

6. Visualización simultanea de dos imágenes georreferenciadas, en dos ventanas distintas, y capacidad de enlazarlas para estudiar localización de puntos comunes.

4.3. Cálculo de estadísticas e histograma de la imagen

Ya hemos indicado que cualquier operación aplicada sobre la imagen parte de comprender su carácter digital. Al igual que cualquier variable estadística, la operación más elemental que podemos realizar con una imagen es describir su tendencia central y dispersión. En otras palabras, conocer cuál es la tendencia general de la radiancia detectada en cada banda, y qué nivel de homogeneidad existe entre los píxeles que la componen. Para ello, cualquier programa de ADI facilita el cálculo de las estadísticas elementales de la imagen, al menos de las medidas de tendencia central y dispersión más habituales. Recordando aspectos de estadística descriptiva, la media puede definirse como:

$$\overline{ND}_k = \frac{\sum_{i=1,n} ND_{i,k}}{n_k} \qquad \{6.1\}$$

para las k bandas que forman la imagen, y los n píxeles que la componen, y la desviación típica como:

$$s_k = \sqrt{\frac{\sum_{i=1,n} (ND_{i,k} - \overline{ND}_k)^2}{n_k}} \qquad \{6.2\}$$

Estas medidas nos ofrecen una primera valoración sobre el carácter de cada una de las bandas y su grado de homogeneidad. Las correspondientes a Torre100 aparecen en la tabla 6.1. De esta tabla se deduce que la banda 1 ofrece el ND más bajo de los mínimos de todas las bandas, lo que puede ser consecuencia del efecto de dispersión atmosférica, como luego veremos. Los ND medios son más altos para las bandas 4 y 5, bastante saturadas a juzgar por los valores mínimo y máximo, muy

TABLA 6.1. *Estadísticas elementales de la imagen de Torre100*

	Máximo	*Mínimo*	*Media*	*Desv. típica*
Banda 1	100	48	69,26	8,87
Banda 2	90	27	55,63	10,80
Banda 3	120	22	48,50	15,25
Banda 4	160	10	91,13	22,87
Banda 5	170	8	91,86	23,46
Banda 7	135	5	62,21	19,84

1. Los números refieren a ND. No se ha incluido la banda térmica.

próximos a 0 y 255, respectivamente. La banda 5 acoge también la mayor heterogeneidad, aunque no muy distinta de la banda 4. Por su parte, la banda 1 ofrece la menor dispersión. Lógicamente, estos valores numéricos se relacionan con los parámetros de calibración del sensor y con las regiones del espectro que abarca. Como resulta evidente, la banda 5 es la más sensible a alteraciones de radiancia, mientras la 1 ofrece el peor contraste en la escena.

Además de estos valores medios, también resulta de gran interés contar con el histograma de frecuencias de cada banda (número de píxeles que cuentan con un determinado ND), que nos informa sobre cómo se distribuyen los ND en una determinada imagen. Con objeto de facilitar la representación del histograma, las frecuencias absolutas suelen convertirse a relativas, de acuerdo a las siguiente fórmula:

$$FR(ND_i) = \frac{F(ND_i)}{\sum_{i=1,\,m} F(ND_i)} \qquad \{6.3\}$$

Esto es, la frecuencia relativa (*FR*) de un determinado ND (p. ej., el valor 120) se calcula como el cociente entre el número de píxeles que presentan ese valor ($F(ND_i)$) y el total de píxeles de la imagen. Esa proporción sirve para escalar el histograma, a partir de la frecuencia relativa mayor.

Varios autores han puesto de relieve el interés del histograma para realizar una primera valoración de la imagen (Castleman, 1978; Jensen, 1996). Su localización nos permite deducir la tonalidad dominante de cada banda; su anchura está relacionada con el contraste, mientras la presencia de picos relativos puede ser testigo de determinadas clases de cobertura. Por ejemplo, para el caso de la imagen de nuestro ejemplo, los histogramas de los ND (fig. 6.10) nos permiten realizar algunos comentarios interesantes. Por un lado, todos ellos ocupan sólo un pequeño margen del rango de variación ofrecido por el equipo de visualización (0 a 255). Esto implica la conveniencia de ajustar, de alguna forma, la variación inicial a la máxima permitida, lo que supondrá una mejora del contraste (ver 6.5.1). Entre las bandas aquí incluidas, la 4 y la 5 se confirman como las que ofrecen mayor dispersión. Recuérdese que poseen la desviación típica más alta, mientras la 1 y la 2 presentan el histograma más estrecho. En cuanto al significado de los distintos picos de frecuencia, resulta muy complicado identificar las cubiertas que los originan. Puede resultar

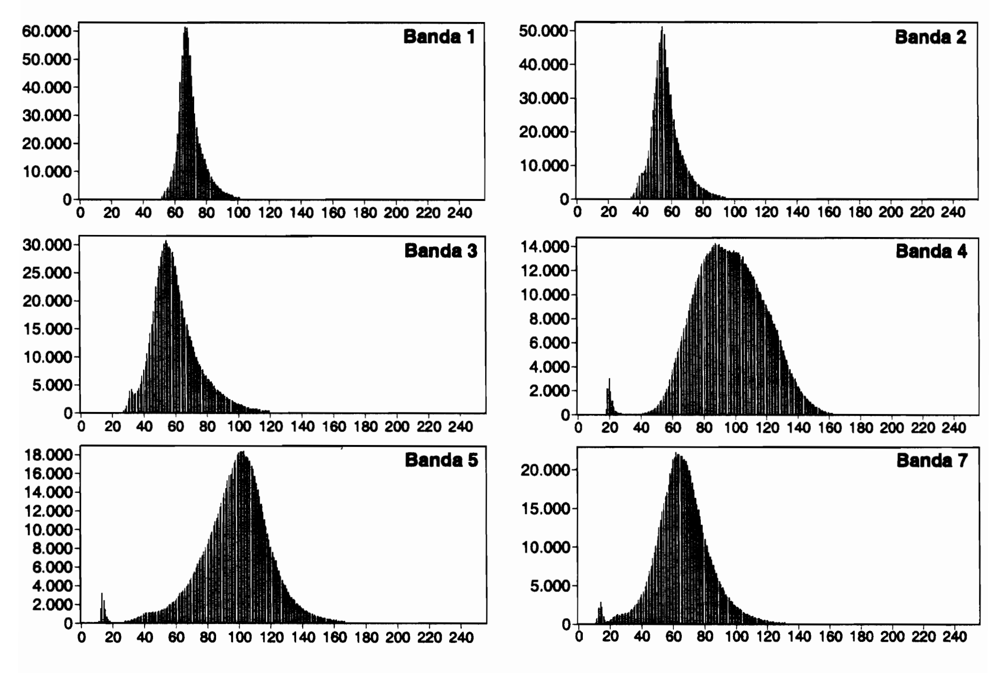


FIG. 6.10. *Histogramas de las bandas ópticas de la imagen de Torrelaguna. La escala horizontal va de 0 a 255.*

más sencillo en otros casos. Por ejemplo, el mínimo relativo observado en las bandas 4 a 7, en los valores más bajos, parece lógico que corresponda a las áreas inundadas por embalses ya que en esta banda el agua presenta su máxima absorción, es decir refleja poca energía.

Además de la consideración de cada banda por separado, también resulta de interés tener en cuenta las relaciones entre bandas, con objeto de analizar el grado de información original que aporta cada una. Este análisis puede realizarse gráficamente, mediante la construcción de dispersogramas, que presentan en un gráfico bivariado la localización espectral de los píxeles de la imagen en dos bandas a partir de sus ND. Cuando la nube de puntos en estos gráficos tiendan a formar una línea (o una elipse de ejes muy contrastados), las dos bandas tenderán a estar muy relacionadas. En otras palabras, puede ser suficiente trabajar con una de ellas reteniendo la mayor parte de la información original. Esto ocurre, típicamente, entre las bandas visibles (en el caso del Landsat-TM/ETM+ las 1, 2 o 3) o las situadas en el SWIR (las 5 y 7). Por el contrario, si la nube de puntos ofrece alta dispersión, la relación entre las bandas será pequeña o, lo que es lo mismo, las dos ofrecen información contrastada y ambas son de interés para el análisis, como ocurre con la relación entre el IRC y el VIS. Por ejemplo, en la figura 6.11 se recoge la correlación gráfica entre las bandas 1-2 y 3-4 de nuestra imagen de ejemplo. Las dos primeras se sitúan en el espectro visible, y tienen una elevada correlación pues muchas cubiertas terrestres poseen una reflectividad muy similar entre ellas. En consecuencia, la nube de puntos tiende a presentar una forma muy alargada. Por el contrario, entre las ban-

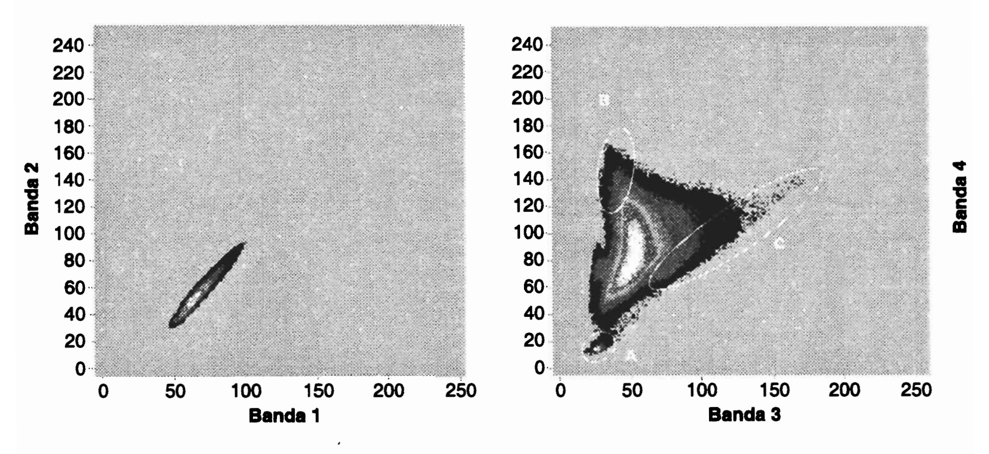


FIG. 6.11. *Diagramas de dispersión de las bandas 1-2 (izda.) y 3-4 (dcha.).*

das 3 y 4 (R, IRC) existe mucha menor similitud, al tratarse de dos bandas con mayor contraste espectral, especialmente en lo que se refiere a las cubiertas vegetales (alta reflectividad en la 4, baja en la 3). En consecuencia, a partir del análisis de la nube de puntos podemos incluso distinguir algunas cubiertas: bajos ND en las dos (A en la fig. 6.11) identificarán al agua; bajos en la 3 y altos en la 4 identificará la vegetación (B), y altos en las dos, identificarán el suelo (C).

Este análisis gráfico se completa con el cálculo de algún índice numérico de la relación entre bandas. Uno de los más empleados es el coeficiente de correlación lineal de Pearson, definido como el cociente entre la covarianza de las dos bandas *m* y *l*, y el producto de sus desviaciones típicas:

$$r_{m,l} = \frac{\left(\sum_{i=1,n}(ND_{m,i} - \overline{ND}_m)(ND_{l,i} - \overline{ND}_l)\right)/n}{s_m\, s_1} \qquad \{6.4\}$$

de sentido análogo a los símbolos incluidos en {6.1} y {6.2}. En este caso, la correlación entre las bandas incluidas en la figura 6.12 ofrece un valor alto, como es esperable, entre la 1 y la 3 (r = 0,95), mientras la 3 y la 4 muestran una correlación mucho más baja (r = 0,35).

Otro aspecto que puede ayudar a entender la radiometría de la imagen es la construcción de perfiles espectrales. La técnica parte de digitizar sobre la imagen una línea que recoja las cubiertas que quieren inspeccionarse, de cara a analizar la variación espacial de los ND en las distintas bandas. En nuestro caso, hemos seleccionado un pequeño transepto que atraviesa un sector de agua, un banco de arena, apenas perceptible, y una zona de pastizal, bastante vigoroso en esta época del año (fig. 6.12). Las tres bandas parten de valores bajos, identificando al agua, para ir aumentando según cruzan otros tipos de cobertura. Cuando se trata de suelos descubiertos, las tres suben al unísono, mientras que lo hace con mayor intensidad la banda 4 cuando atravesamos una zona de mayor actividad clorofílica, que presentará absorción en la banda 3 y, en menor medida, en la 5.

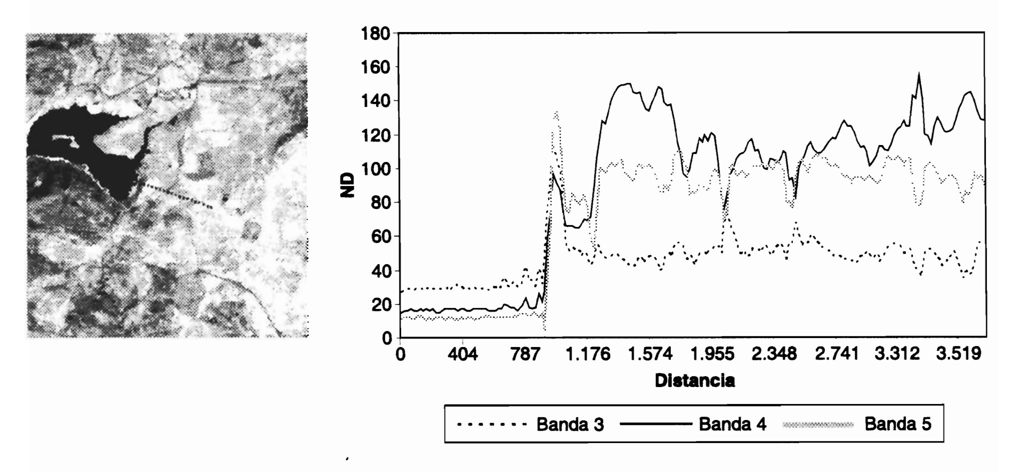


FIG. 6.12. *Perfil radiométrico sobre una ventana de la imagen Torre100.*

Finalmente, nos parece oportuno también considerar la capacidad de obtener perfiles espectrales, de gran interés especialmente para imágenes hiperespectrales. Se trata de gráficos multibanda, que muestran el ND o reflectividad de un determinado píxel para todas las bandas que forman la imagen. Cuando el número de bandas es suficientemente grande y las imágenes están bien calibradas, pueden obtenerse gráficos similares a las firmas espectrales comentadas en el capítulo 2 (fig. 6.13).

5. Realces y mejoras visuales

En este epígrafe se consideran aquellas técnicas dirigidas hacia la mejora de la calidad visual de la imagen. Tratan de disponer mejor los datos para su análisis vi-

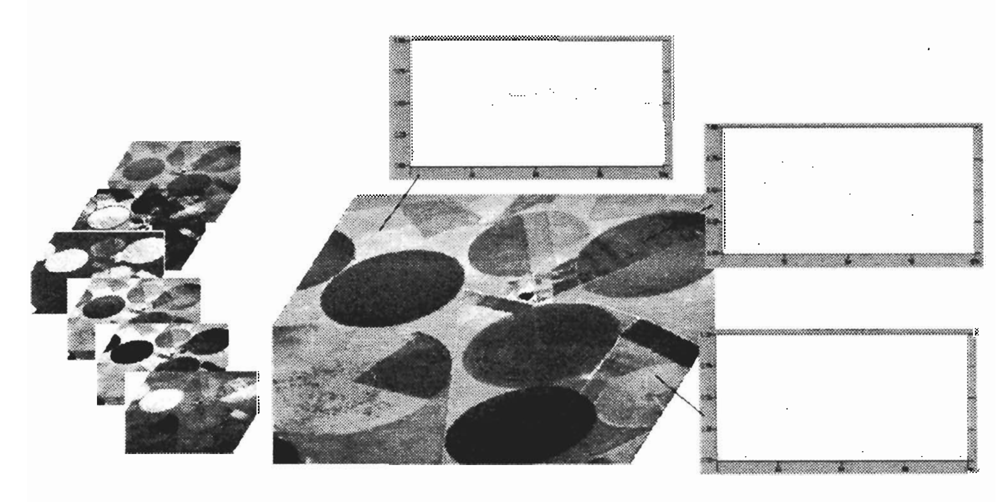


FIG. 6.13. *Perfiles espectrales sobre una imagen hiperespectral adquirida por el sensor aeroportado Hymap (imagen Barrax99).*

sual, de tal forma que sean más evidentes los rasgos de interés que presenta la imagen. Se incluyen en este apartado los procesos de mejora del contraste, composiciones coloreadas, cambios de escala, y filtrajes.

5.1. Ajuste del contraste

Los procesos de ajuste del contraste tienden a adaptar la resolución radiométrica de la imagen a la capacidad del monitor de visualización. Como ya vimos anteriormente, cada sensor codifica la radiancia recibida en un número determinado de ND, de acuerdo a las características de su diseño. Ese rango digital puede no corresponder con el número de niveles visuales (NV) que facilita la memoria gráfica, por lo que resulta preciso ajustar, por algún procedimiento, ambos parámetros. En este sentido, caben dos situaciones obvias: 1) que el rango de ND de la imagen sea menor que el de NV facilitado por el sistema de visualización, y 2) que la imagen presente un mayor número de ND que posibles NV. En el primer caso, se deberá aplicar una expansión del contraste original, mientras en el segundo una reducción del mismo.

La idea de contraste digital puede ilustrarse con un símil fotográfico. Una fotografía aparece con poco contraste, desvaída, cuando no existe una gran diferencia entre sus tonos más claros y más oscuros. De la misma forma, podemos definir digitalmente el contraste por relación a los ND máximo y mínimo de una imagen. Tal definición puede apoyarse en cualquiera de las medidas de dispersión comúnmente utilizadas en estadística (Schowengerdt, 1983):

$$C_1 = ND_{max} / ND_{min} \quad \{6.5\}$$

$$C_2 = ND_{max} - ND_{min} \quad \{6.6\}$$

$$C_3 = s_{ND} \quad \{6.7\}$$

Aquí aparecen tres definiciones digitales del contraste: el cociente entre el valor máximo y el mínimo, el rango, y la desviación típica de los ND de la imagen. A partir de estas medidas, puede juzgarse la necesidad de expandir o comprimir el contraste, en función de las capacidades de visualización ofrecidas por el sistema. Hasta el momento, el primer proceso ha sido empleado rutinariamente en la mayor parte de las aplicaciones. En cuanto a la compresión del contraste, resulta una materia de creciente interés con objeto de reducir el volumen de almacenamiento de las imágenes y facilitar su transmisión por internet. A continuación se presentan con mayor detalle ambos procesos. Se inicia ese comentario con el análisis de la técnica que permite aplicarlos operativamente: el diseño y empleo de las tablas de color.

5.1.1. *Tablas de referencia del color*

Una tabla de referencia del color (*Color Look Up Table*, CLUT), o simplemente tabla de color, es una matriz numérica que indica el nivel visual (NV) con el que

NV (azul)	NV (verde)	NV (rojo)
1	1	1
2	2	2
3	3	3
...	...	...
255	255	255

a)

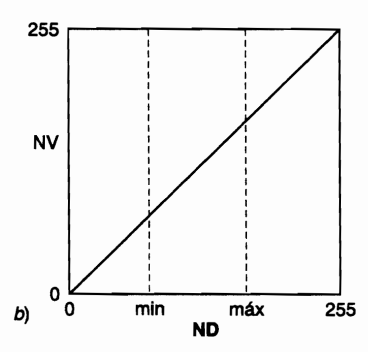


FIG. 6.14. *Estructura tabular (*a*) y representación gráfica de una tabla de color (CLUT) (*b*).*

se representa en pantalla cada uno de los ND de la imagen. La CLUT se inserta entre la memoria de refresco y el tubo de imagen del monitor, lo que permite modificar la relación entre el ND almacenado en disco y la intensidad de brillo con que se visualiza (NV). En otras palabras, ambos valores no tienen por qué ser iguales.

En la mayor parte de los equipos de ADI, la CLUT es una matriz numérica de 3 columnas por 256 filas. El orden de la fila indica el ND de entrada, mientras el almacenado en la tabla expresa el nivel visual (NV), con el que ese ND será representado en pantalla. Las tres columnas corresponden a los tres colores elementales (RVA: fig. 6.14*a*).

Conviene recordar que los equipos de ADI utilizan el proceso aditivo de formación del color (5.2.2), por lo que cuanto mayores sean los valores de NV en cada columna, mayor componente de RVA tendrá el píxel finalmente visualizado. Caso de que se esté manipulando una sola banda, lo normal es que la imagen aparezca en pantalla en tonos de gris. Esto significa que cada ND tiene el mismo componente RVA. Un NV de 0, 0, 0, indica que el ND al que se aplique será visualizado como negro, mientras que 127, 127, 127, supone un gris medio y 255, 255, 255, blanco. En caso de que los tres valores sean distintos, se estará representando una imagen en color, ya sea con una o con tres bandas.

Por cuanto una CLUT implica una relación numérica entre ND y NV, ésta puede también representarse gráficamente en un diagrama bivariado, en donde el ND de la imagen se sitúa en el eje *X*, y el NV en el eje *Y*. Si se visualiza la imagen original, sin ningún realce, la CLUT puede describirse gráficamente como una línea recta, que pasa por el origen 0, 0 y por el máximo 255, 255 (fig. 6.14*b*), lo que supone que el NV sea igual al ND. Con los procesos de expansión o compresión del contraste se modifica esa relación, de tal forma que los NV se distribuyan adecuadamente en el rango de la imagen.

La utilidad de estas tablas numéricas puede comprenderse fácilmente con un ejemplo. Supongamos que se pretende expandir el contraste en una imagen que presente un rango de ND entre 0 y 127. Para ajustar dicho rango al que permite el equipo de visualización (0 a 255), bastaría multiplicar por dos cada ND de entrada, lo que ampliaría su contraste a un rango entre 0 y 254. Ahora bien, tal opción conlleva dos problemas importantes: por un lado, transformar los ND iniciales para crear una nueva imagen de salida, lo que implica, o bien perder la información original,

o bien aumentar las necesidades de almacenamiento; por otro lado, ese proceso supone un volumen de operaciones considerable: 786.432 multiplicaciones para una pequeña zona de 512 × 512 píxeles y tres bandas. Si consideramos que el realce es sólo una etapa intermedia, y normalmente efímera del proceso, parece lógico buscar una alternativa a ese método. Gracias a la CLUT no es preciso transformar los ND para modificar el contraste visual de la imagen. Basta únicamente transformar la relación entre ND y NV que incluye la CLUT, de acuerdo al criterio que se estime más oportuno. En el ejemplo anterior, podría generarse una sencilla función donde NV = 2 × ND, con lo que se obtendría el mismo efecto visual que la multiplicación de todos los ND, con un considerable ahorro de tiempo, pues la modificación de una CLUT sólo supone 768 cálculos (256 NV × 3 cañones de color), independientemente del tamaño de la imagen.

A continuación se presentan las técnicas más habituales para generar CLUT de cara al realce digital de imágenes, así como para la visualización en seudo-color de una sola banda.

5.1.2. *Compresión del contraste*

En caso de que el rango del sensor supere al número de niveles de gris que pueden visualizarse en pantalla, resulta preciso comprimir los ND originales, ajustando el rango de la imagen al permitido por el terminal gráfico. Estos ajustes son necesarios en dos casos: 1) cuando se cuenta con un sistema gráfico de reducida potencia, o 2) cuando se trabaja con un sensor de gran resolución radiométrica.

La mayor parte de los equipos de visualización cuentan con una resolución en pantalla de 8 bits para cada uno de los tres cañones de color (rojo, verde y azul). Esto permite visualizar una banda en 256 niveles de gris, o tres en unos 16,8 millones de tonos de color (= 256^3). En los años noventa, las tarjetas gráficas disponían de poca memoria, lo que suponía visualizar la imagen con un rango muy limitado de colores (habitualmente 256 por píxel). Esto suponía que sólo una parte del rango original de ND podría visualizarse en pantalla, y se hacía necesario aplicar algún algoritmo para comprimir ese contraste original. Ahora estas situaciones son mucho menos frecuentes, pues las memorias gráficas disponen de capacidad suficiente para visualizar hasta 24 bits por píxel. Sin embargo, las técnicas de compresión siguen siendo de interés cuando el sensor empleado tiene una gran sensibilidad radiométrica (como ocurre con las imágenes NOAA-AVHRR, codificadas en 10 bits por banda; las IKONOS, en 11 bits, o las RADAR (frecuentemente en 16 bits).

El problema puede solventarse de dos formas: eliminando una parte de la escala que no se considere relevante, o estableciendo una función de compresión de datos. La primera solución es bastante obvia, aunque poco habitual ya que supone una eliminación arbitraria de datos. La segunda puede abordarse por distintos criterios. Lo más habitual es reducir el rango original de ND a un número conveniente de intervalos, de forma que la visualización en color resultante se asemeje en lo posible al color real. Esos intervalos suelen señalarse en función de las características de la distribución de los ND. Pueden indicarse intervalos de igual anchura, que contengan el mismo número de elementos, o que tengan unos márgenes delimitados por el intérprete. En cualquier caso, a cada uno de ellos se le asigna un único NV, eliminan-

do su variación interna. Al reducirse el contraste de la escena, los colores se diferencian menos entre sí, reduciéndose la calidad de la visualización. No obstante, si la selección de colores es apropiada puede lograrse una visualización de bastante calidad. Para el caso de 3 bandas, resulta habitual asignar 6 niveles a cada cañón de color, con lo que la composición contará con 216 tonalidades en pantalla (6^3). Existen otros algoritmos de compresión de imagen algo más refinados, que controlan el número de intervalos asignables a cada banda de la composición en color mediante un proceso similar a la clasificación no supervisada de la imagen que luego veremos (Baudot, 1990; Muller, 1988*a*). Normalmente, parten de establecer una serie de particiones en el espacio tri-dimensional formado por las tres bandas que forman una composición en color. En función de la anchura del histograma de cada banda se asignan más o menos particiones por color. Para asignar un intervalo de ND a cada una de esas particiones, se establece el rango de variación más significativo en cada una de las bandas, calculado a partir de su media y desviación típica. Finalmente, se clasifican los ND de la imagen en la partición más cercana en ese espacio. El resultado del proceso es una nueva imagen, mono-banda, que se asocia a una CLUT para representar, con la mayor semejanza posible, la variación cromática de la composición multi-banda, aunque sólo precisa la tercera parte de almacenamiento.

También pueden aplicarse algoritmos estándar de compresión de color, bien conocidos en la informática gráfica, como el LZW, que permite crear imágenes GIF (*Graphics Interchange Format*), muy utilizado en la edición de páginas web, aunque limitado a 256 colores, el JPEG *(Joint Photographic Expert's Group)*, que acepta hasta 24 bits por píxel y garantiza ratios de compresión de hasta 20:1 sin apreciable pérdida de calidad, y el PNG *(Portable Network Graphics)*, desarrollado por *Compuserve* y *W3C*, que acepta también hasta 24 bits por píxel e incluso una capa adicional para superposiciones, aunque los ratios de compresión no son tan altos como los JPEG. Últimamente se han desarrollado nuevas técnicas para la compresión masiva de imágenes, de cara a su distribución a través de internet. Entre ellas, están teniendo bastante aceptación las basadas en onditas *(wavelets)*, que consiguen índices de compresión bastante altos con baja o nula pérdida de información.(Taubman, 2002).

5.1.3. *Expansión del contraste*

Más habituales que los procesos de compresión son las técnicas de realce del contraste, porque la mayor parte de las imágenes ofrecen un rango real de ND inferior a las capacidades del equipo de visualización. Aunque la resolución radiométrica de buena parte de los sensores es de 8 bits por píxel, en la práctica ninguna imagen aprovecha todo ese rango, ya que difícilmente en una sola escena se encontrarán todos los posibles valores de ND para los que se calibró el sensor. De esta forma, el histograma real de los ND de cualquier imagen nunca satura los 256 posibles ND de la imagen. Visualmente esto implica que haya tonos de gris que no se utilicen, con lo que la imagen aparece en el monitor con poco contraste.

Por ejemplo, la figura 6.15*a* presenta la banda 3 de nuestra imagen de ejemplo, tal y como corresponde a sus ND originales. Como puede observarse, la imagen ofrece un bajo contraste, difuminándose algunas características de interés.

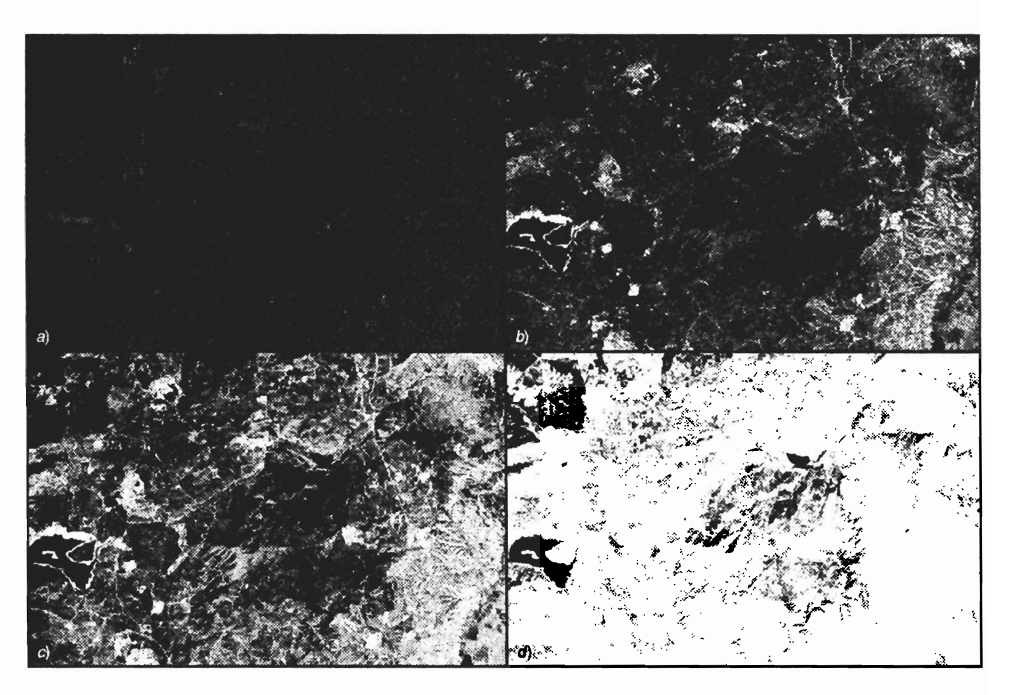


FIG. 6.15. *Diversos realces del contraste sobre la banda 1 de la imagen Torre100: (*a*) sin realce; (*b*) realce lineal; (*c*) realce frecuencial; (*d*) realce especial sobre áreas de baja radiancia.*

Como ya vimos al analizar el histograma, esta banda presenta un rango de ND que ocupa sólo un pequeño sector de los 256 ND posibles, lo que confirma su reducido contraste.

De acuerdo a las ideas antes comentadas, es posible realzar ese contraste, diseñando una CLUT que haga corresponder el rango de ND presente en la imagen con el total de los NV posibles. Varios procedimientos pueden conseguir este objetivo: 1) distribuir los NV linealmente, entre el máximo y mínimo ND de la imagen (fig. 6.15*b*), 2) distribuir los NV a partir del histograma de los ND originales (fig. 6.15*c*), y 3) distribuir los NV en un determinado rango de ND de interés (fig. 6.15*d*). Éstos son los tres procesos de expansión del contraste que a continuación se analizan. Para presentar estos realces, consideraremos una CLUT de una sola columna. Si se pretende un realce para una composición en color, se seguiría un modelo similar para expandir cada una de las tres bandas que la formen.

5.1.3.1. Expansión lineal

Es la forma más elemental de ajustar el contraste de la imagen al permitido por el equipo de visualización. Basta diseñar una CLUT en la que el ND mínimo y máximo de la imagen tengan asociados un NV de 0 y 255, respectivamente, distribuyendo linealmente el resto entre ambos márgenes. En la figura 6.15*b* aparece la imagen anteriormente presentada tras aplicarle una expansión lineal del contraste. Como puede observarse, la imagen aparece ahora más nítida, mejor contrastada. Su histo-

grama ofrece una distribución más equilibrada (fig. 6.16*a*). Las colas del histograma se han fijado en los extremos del rango y los valores intermedios están mejor repartidos en la escala. La representación gráfica de la CLUT supone una línea de mayor pendiente que la anterior, comprendida ahora entre los ND mínimo y máximo de la imagen.

Para llevar a efecto esta transformación se precisa encontrar una función lineal, que ajuste la relación ND-NV de acuerdo a la relación antes comentada. Esa función nos permite construir una CLUT apropiada, en la que se sustituya la correspondencia NV = ND, por una nueva, en donde los NV ocupen el rango completo de visualización y no sólo el que ofrece la imagen original. En definitiva, se trata de establecer una ecuación lineal del tipo siguiente:

$$\mathrm{NV} = a + b\ \mathrm{ND} \qquad \{6.8\}$$

en donde cada NV es una función de los ND originales, tras aplicarles dos constantes, denominadas *a*, constante y *b*, pendiente. Para conocer el valor de *a* y *b*, basta aplicar un sencillo sistema de ecuaciones. Ya que sabemos que el mínimo y el máximo ND deben igualarse a 0 y 255, respectivamente, puede expresarse:

$$0 = a + b\ \mathrm{ND}_{min}$$

y

$$255 = a + b\ \mathrm{ND}_{max}$$

Sustituyendo en ambas fórmulas, los coeficientes se calculan como:

$$b = \frac{255}{ND_{max} - ND_{min}} \qquad \{6.9\}$$

y

$$a = \frac{-255 \cdot ND_{min}}{ND_{max} - ND_{min}} \qquad \{6.10\}$$

Aunque la transformación puede expresarse en un solo término como:

$$NV = \frac{ND - ND_{min}}{ND_{max} - ND_{min}} \cdot 255 \qquad \{6.11]$$

En lugar de igualar el ND_{max} y el ND_{min} a los valores máximo y mínimo, respectivamente, también pueden extraerse otros valores menos extremos, como los percentiles del 95 y 5 %, o un cierto número de desviaciones típicas por encima y

TABLA 6.2. *Expansión lineal de la imagen Torre100 (Media ± 2 S)*

ND	*NV*	*ND*	*NV*	*ND*	*NV*	*ND*	*NV*
0	0	65	154	130	255	195	255
5	0	70	175	135	255	200	255
10	0	75	196	140	255	205	255
15	0	80	217	145	255	210	255
20	0	85	238	150	255	215	255
30	8	95	255	160	255	225	255
35	29	100	255	165	255	230	255
40	50	105	255	170	255	235	255
45	71	110	255	175	255	240	255
50	91	115	255	180	255	245	255
55	112	120	255	185	255	250	255
60	133	125	255	190	255	255	255

1. Los números refieren a ND. No se ha incluido la banda térmica.

por debajo de la media. Esto permitirá que tengan menos influencia posibles valores extremos y/o anómalos que presente la imagen.

Un ejemplo concreto puede ayudar a comprender mejor el proceso. Para obtener la expansión lineal del contraste antes presentada, se partió de las medidas estadísticas de la banda 3 (tabla 6.1) que sirvieron para aplicar las fórmulas anteriores. En este caso, se estableció un umbral mínimo y máximo a partir de la media ± dos desviaciones típicas. En consecuencia, el rango a expandir se situó entre 28 y 89 ND. De acuerdo a {6.9 y 6.10}:

$$b = 255 \ / \ (89\text{-}28) = 4{,}18$$

y

$$a = (-255 \cdot 28) \ / \ (89\text{-}28) = -117{,}05$$

Con estos valores puede construirse la CLUT que aparece en la tabla 6.2, de acuerdo a la siguiente expresión:

$$NV = ENT\ (-117{,}05 + 4{,}18\ ND)$$

la expresión ENT indica que el resultado se redondea al entero más cercano. Además, NV = 0 cuando NV < 0, y NV = 255 cuando NV > 255, puesto que la tabla de color sólo puede estar formada por números enteros entre 0 y 255. Esta tabla puede representarse gráficamente, de forma similar a cualquier recta de regresión (fig. 6.16).

5.1.3.2. Ecualización del histograma

La expansión lineal del contraste no tiene en cuenta la distribución de los ND en una imagen, sino sólo sus extremos. Parece lógico, sin embargo, tener en cuenta

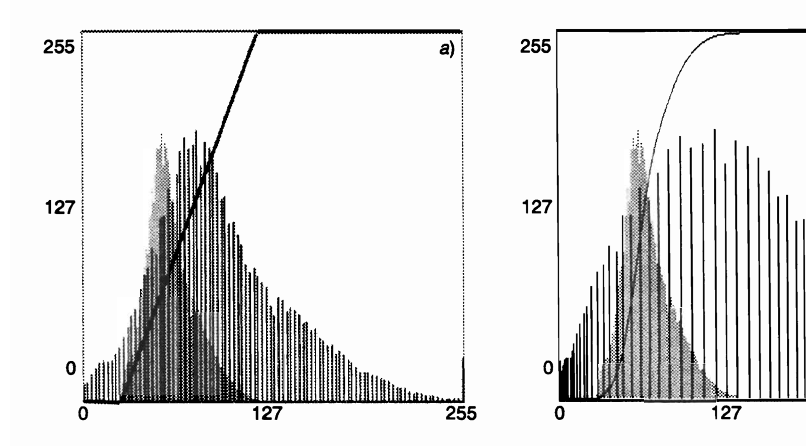


FIG. 6.16. *Modificaciones en el histograma de la imagen y perfil de la CLUT tras la expansión:* a) *lineal,* b) *frecuencial. El histograma original aparece al fondo en gris.*

la distribución real de valores, aplicando una expansión proporcional a la frecuencia de aparición de cada uno de los ND. Esto implica generar una CLUT en la cual cada NV tenga, aproximadamente, el mismo número de ND de la imagen. En otras palabras, aquellos ND con mayor número de píxeles serán los que, proporcionalmente, ocupen un mayor rango de NV. Suele ofrece mejores resultados que la expansión lineal, especialmente si la imagen original presenta una distribución gausiana.

Como puede observarse en la figura 6.15*c*, la ecualización del histograma ha supuesto un realce más equilibrado, mostrando menos contraste entre las zonas de alta reflectividad y las de baja. A consecuencia de este realce, el histograma de la imagen ofrece una mejor distribución de los datos (fig. 6.16*b*). También se evidencia que el perfil gráfico de la CLUT no es recto sino curvilíneo, similar al que tendría el histograma acumulado de los ND originales.

La lógica de cálculo pasa por igualar el histograma de los NV con el de los ND. Para construir una CLUT con un trazado similar al histograma de la imagen, puede seguirse el siguiente proceso:

1. Calcular la frecuencia absoluta y acumulada de los ND de la imagen original.
2. Esta frecuencia se compara con una frecuencia objeto, que sería la que se obtendría si todos los NV de la imagen tuvieran la misma frecuencia (el cociente entre el total de píxeles de la imagen y el número de NV posibles). En nuestro caso, la frecuencia objeto sería 736.136 / 256; esto es, 2875,53 píxeles por cada NV. Trabajando con frecuencias relativas, cada NV debería albergar el 0,3906 % de los píxeles de la imagen. Estos valores también se acumulan para compararlos con la frecuencia acumulada de los ND de la imagen.
3. De esta comparación se selecciona, para cada ND, el NV que presente un valor más próximo en la frecuencia objeto acumulada.

En la tabla 6.3 se incluye un resumen de los cálculos necesarios para obtener una tabla de color con expansión frecuencial. Para simplificar las cosas, hemos se-

TABLA 6.3. *Realce frecuencia del contraste*

ND	*Frecuencia relativa*	*Frecuencia relativa acumulada*	*Frecuencia objeto*	*NV*
0	0,000	0,000	1,953	0
5	0,000	0,000	3,906	0
10	0,000	0,000	5,859	0
15	0,000	0,000	7,813	0
20	0,000	0,000	9,766	0
25	0,056	0,056	11,719	0
30	1,330	1,387	13,672	0
35	4,634	6,021	15,625	10
40	6,972	12,993	17,578	30
45	8,815	21,808	19,531	50
50	11,656	33,464	24,484	80
55	11,731	45,195	23,438	110
60	10,990	56,184	25,391	140
65	12,347	68,532	27,344	170
70	10,240	78,772	29,297	195
75	7,913	86,686	31,250	215
80	4,853	91,539	33,203	230
85	3,142	94,681	35,156	235
90	2,155	96,836	37,109	240
95	1,119	97,955	39,063	245
100	0,778	98,732	41,016	250
105	0,516	99,249	42,969	255
110	0,300	99,548	44,922	255
115	0,203	99,752	46,875	255
120	0,109	99,860	48,828	255
125	0,058	99,919	50,781	255
130	0,029	99,948	52,734	255
135	0,017	99,965	54,688	255
140	0,010	99,975	56,641	255
145	0,011	99,986	58,594	255
150	0,007	99,993	60,547	255
155	0,004	99,996	62,500	255
160	0,002	99,998	64,453	255
165	0,000	99,999	66,406	255
170	0,001	99,999	68,359	255
175	0,000	100,000	70,313	255
180	0,000	100,000	72,266	255
185	0,000	100,000	74,219	255
190	0,000	100,000	76,172	255
195	0,000	100,000	78,125	255
200	0,000	100,000	80,078	255
205	0,000	100,000	82,031	255
210	0,000	100,000	83,984	255
215	0,000	100,000	85,938	255
220	0,000	100,000	87,891	255
225	0,000	100,000	89,844	255
230	0,000	100,000	91,797	255
235	0,000	100,000	93,750	255
240	0,000	100,000	95,703	255
245	0,000	100,000	97,656	255
250	0,000	100,000	99,700	255
255	0,000	100,000	100,000	255

leccionado únicamente rangos de 5 ND. En consecuencia, cada intervalo en la frecuencia objeto debería presentar 1,95 % de los píxeles de la imagen. Como observamos en esta tabla, el NV correspondiente a todos los ND inferiores a 25 es 0, porque su frecuencia objeto más similar es la correspondiente al NV = 0 (la frecuencia acumulada de la imagen en todo ese rango es 0,056 y la frecuencia objeto acumulada es 1,95). De la misma forma, al ND = 40 le corresponde el NV = 30, porque su frecuencia acumulada (12,993) es más similar a la del NV = 30 (13,672), y así sucesivamente hasta culminar el proceso.

5.1.3.3. Expansión especial del contraste

Supone un caso particular de los métodos anteriormente estudiados. La novedad radica en restringir el contraste a un rango específico de ND, en donde se manifieste con mayor claridad una cubierta de interés. Por ejemplo, en una aplicación sobre zonas marinas, convendrá resaltar especialmente la visualización de los valores más bajos del histograma, aunque se pierda contraste en otros rangos de la imagen.

La expansión especial puede realizarse señalando un umbral máximo y mínimo, acorde con el rango digital de la cubierta que pretende realzarse (método lineal), o limitando el histograma objeto a una ventana de la imagen donde esté presente dicha cubierta (realce frecuencial). En ambos casos, esta operación supone afinar mucho más la representación visual de esa cubierta, en detrimento del contraste en otras áreas. Una muestra de este realce puede observarse en la figura 6.15*d*, que recoge una expansión parcial sobre las zonas de baja radiancia (forestales y agua). Como puede observarse, queda más en evidencia la variación interna de estas cubiertas, especialmente en el caso de los embalses de la imagen y las zonas forestales situadas en el límite occidental. En estos sectores pueden observarse algunas diferencias internas apenas perceptibles en los anteriores contrastes. Como contrapartida, centrarnos sobre ese rango implica perder definición en el resto del rango tonal de la imagen, como consecuencia de haber expandido un intervalo de visualización muy pequeño.

Un caso particular de este tipo de expansiones sería la binarización de la imagen, si bien no es propiamente una expansión, sino una compresión del contraste, pues su objeto es convertir la imagen a dos tonos, blanco y negro. La CLUT aparecerá con un perfil similar a un escalón, el primer «peldaño» sitúa todos los rangos que ocuparán un tono negro, y el segundo los que presentarán un tono blanco. Este tipo de procesos se utilizan para aislar un sector de ND de interés para un análisis posterior. Por ejemplo, pueden separarse los ND correspondientes a la zona de agua en un estudio oceanográfico, de cara a evitar los ruidos que podrían llevar consigo las zonas costeras. Lógicamente en este caso, no se trata de una expansión, sino de una compresión del contraste, muy drástica pues toda ella quedaría reducida a dos niveles.

5.2. Composiciones en color

A partir de la información multi-espectral que generan la mayor parte de los sensores, pueden obtenerse distintas composiciones de color. Basta para ello aplicar

cada uno de los tres colores primarios (rojo, verde y azul) a una banda distinta de la imagen, seleccionada con el criterio y en el orden que se estime más oportuno. El proceso permite visualizar, simultáneamente, información de distintas regiones del espectro, lo que facilita la delimitación visual de algunas cubiertas. Por tratarse de bandas distintas, la CLUT aplicada a una composición en color presenta tres columnas con distintos valores. Normalmente, éstos se corresponden con los obtenidos en una expansión del contraste aplicada por separado a cada una de las tres bandas que intervienen en el proceso.

La elección de las bandas para realizar la composición, y el orden de los colores destinados a cada una, dependen del sensor sobre el que se trabaje y de la aplicación última del proyecto. Como ya vimos anteriormente (5.2.2), la composición más habitual es la denominada falso color o infrarrojo color, fruto de aplicar los cañones de color rojo, verde y azul sobre las bandas correspondientes al IRC, R, V, respectivamente (fig. 12*). Esta composición facilita la cartografía de masas vegetales, láminas de agua, ciudades, etc., de ahí que se haya empleado profusamente en diversos estudios de análisis visual.

Con la creciente proliferación de los sensores hiperespectrales, las posibilidades de realizar composiciones coloreadas de bandas son prácticamente ilimitadas. Lógicamente, solo algunas tendrán un interés específico para una determinada aplicación, y muchas de ellas serán casi idénticas. De cara a establecer algún criterio más objetivo para seleccionar las bandas más adecuadas para una composición en color se han propuesto algunos índices estadísticos y cromáticos, que permiten retener mejor la varianza original de los datos. De esta forma se define el denominado «Índice óptimo» (*Optimum Index Factor*, OIF):

$$OIF = \frac{\sum_{k=1,3} s_k}{\sum_{j=1,3} |r_j|} \qquad \{6.12\}$$

donde s_k indica la desviación típica de cada una de las tres bandas que intervienen en la composición y r_j el coeficiente de correlación entre cada par de esas mismas bandas (Jensen, 1996, pp. 97-100).

Otros métodos propuestos para seleccionar la composición en color idónea tienen en cuenta el elipsoide de máxima variación, que supone un planteamiento novedoso frente a los métodos estadísticos convencionales (Sheffield, 1985) y el valor de la divergencia (Mather, 1998), que luego comentaremos (7.2). Los resultados de estas técnicas muestran una tendencia similar. Para las imágenes TM, con las que se han aplicado profusamente estos índices, la mayor parte selecciona una banda en el VIS, otra en el IRC y otra en el SWIR, identificando así los tres ejes principales de variación en una imagen TM, excluido el térmico.

5.3. Empleo del seudo-color

Varios autores han puesto en evidencia que el ojo humano es más capaz de distinguir tonos de color que intensidades de brillo (Ruiz, 1994). Por tanto, el empleo

TABLA 6.4. *Ejemplo de CLUT para una imagen clasificada*

ND	*NV Rojo*	*NV Verde*	*NV Azul*	*Color resultante*
0	0	0	0	Amarillo
1	255	0	0	Rojo
2	0	255	0	Verde
3	0	0	255	Azul
4	0	255	255	Cian
5	255	255	0	Amarillo
6	255	127	0	Ocre
7	127	127	127	Gris
8	255	0	127	Rosa

del color puede ayudar a la interpretación de una imagen, incluso si sólo disponemos de una banda. En estos casos, no podemos hablar propiamente de color, pues se requerirían tres bandas, sino más bien de seudo-color. Para una mezcla de tres bandas utilizamos distintos NV en cada cañón de color (R, V, A), siendo iguales cuando se visualiza una sola banda (en blanco y negro). Sin embargo, podemos diseñar también una CLUT en donde se varíen los NV para los tres colores, aunque sólo haya una banda de ND de entrada. En otras palabras, el seudo-color implica crear una CLUT que asocie el ND de una sola banda a distintos componentes de rojo, verde y azul. Esto puede tener sentido en dos casos: 1) cuando se pretenda obtener una clave de color en una imagen clasificada, y 2) cuando se intente realzar el análisis de una determinada banda de la imagen, sustituyendo los niveles de gris por tonos de color. También se utiliza el seudo-color cuando se comprime una imagen en color de 24 a 8 bits, generándose una paleta de color que se asimile a la variedad cromática original contenida en la composición de las tres bandas de entrada.

A modo de ejemplo, aparece en la tabla 6.4 una CLUT diseñada para representar visualmente una imagen clasificada. En ella, cada ND indica una clase temática distinta (por ejemplo, una categoría de ocupación del suelo), que será visualizada en pantalla con distintos tonos de color. El ND 1 (supongamos que indique zonas urbanas) se visualizará en color rojo, ya que aplicamos la intensidad máxima de rojo (recordemos que la escala comprende de 0 a 255) y una mínima de verde y azul. De la misma forma, el ND 2, que podría representar cubierta vegetal, se visualizaría en verde, dando un valor máximo a este cañón de color y mínimo a los otros dos. Lógicamente, se pueden plantear colores por mezcla de distintas intensidades de R, V, A. Por ejemplo, el ocre indica una máxima intensidad de rojo y media de verde, sin azul. La paleta de color disponible permite visualizar, por tanto, combinaciones de 256 niveles RVA, o lo que es lo mismo unas 16,8 millones de tonalidades (256^3). Lógicamente, no todos estos colores pueden distinguirse en la práctica, por lo que bastará con seleccionar unos cuantos (entre 10 y 20 suele ser necesario) para construir una clave de color apropiada a cualquier clasificación temática.

También puede emplearse el seudo-color para visualizar en color alguna de las bandas originales, realzando el análisis de esa banda. El seudo-color puede aplicarse al conjunto de los ND de la escena, diseñando una CLUT formada, por ejemplo, por números aleatorios entre 0 y 255, para cada uno de los tres colores. Ahora bien,

esto complicará la interpretación, pues no habrá ninguna escala de referencia para el analista. Por ello, lo más habitual es aplicar una transformación del color progresiva, en donde la CLUT tiene una dirección determinada de gradación: por ejemplo, desde los tonos azules para los ND bajos hasta los rojos, para los más altos. Una aplicación concreta de esta técnica sería la visualización de imágenes de temperaturas (6.6.2.4) o de índices de vegetación (7.1.2), que tratan de representar la intensidad de dos fenómenos físicos (calentamiento y vigor vegetal, respectivamente), y pueden representarse, por ejemplo, por tonos de azul-rojo, en el primer caso, y de ocre-verde, en el segundo.

En estos casos, en lugar de aplicar una CLUT a toda la escala de ND original, puede ser recomendable dividir antes el rango original en una serie de intervalos de densidad *(density slicing)*. Este nombre se emplea para indicar que cada uno de esos grupos corresponde a valores de radiancia relativamente similares. Esto facilita la posterior interpretación visual de los resultados, ya que el observador podrá distinguir con mayor claridad entre diversas categorías. Los umbrales que definen cada intervalo pueden establecerse arbitrariamente o con algún criterio estadístico: por ejemplo, señalando una anchura constante a partir del rango, o seleccionando intervalos de la misma frecuencia. En cualquier caso, los umbrales elegidos pueden modificarse interactivamente, con lo que el usuario puede detectar, en cada banda, el rango de ND que comprende un fenómeno de interés. Asimismo, le facilita un primer balance de los solapes con otras categorías, de cara a su clasificación digital.

5.4. Filtrajes

5.4.1. *Naturaleza de un filtro digital*

Al igual que en las técnicas fotográficas convencionales, el filtro se aplica en análisis digital para aislar componentes de interés. Hemos visto previamente técnicas que mejoran el contraste tonal en la imagen, esto es, la diferencia entre los valores más oscuros y más claros que se visualizan en el monitor. El otro componente de la imagen es el contraste espacial, o si se prefiere la diferencia entre el ND de un determinado píxel y el de sus vecinos. Mediante técnicas de filtraje, se pretende suavizar o reforzar estos contrastes espaciales, de tal forma que los ND de la imagen se asemejen o diferencien más de los correspondientes a los píxeles que les rodean.

Como ya vimos anteriormente, si trazamos un perfil radiométrico en una determinada zona de la imagen (fig. 6.17) observamos numerosos picos y valles, a consecuencia de cambios espaciales bruscos en las características radiométricas de la cubierta del suelo. Como en cualquier serie estadística, esa línea podría considerarse como una suma de dos componentes: las bajas frecuencias, que indicarían la tendencia general de la variación, y las altas frecuencias, que señalarían los contrastes más locales. El propósito de los filtros digitales es retener unas u otras, en función del objetivo que persiga el intérprete. Se denominan, respectivamente, filtros de paso bajo y paso alto. Hay dos procedimientos para llevarlos a cabo: aplicar a todos los píxeles de la imagen una operación aritmética que tenga en cuenta el valor de los inmediatos (filtros en el dominio espacial), o retener ciertos componentes de las

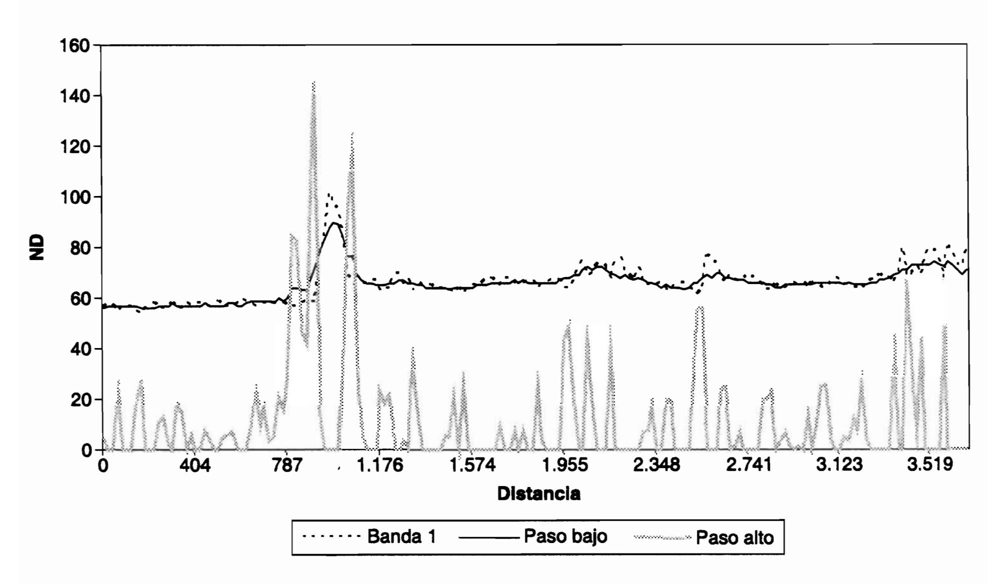


FIG. 6.17. *El mismo perfil recogido en la figura 6.12 sobre la imagen Torre100. Aparecen los ND de la banda 1 original, así como los componentes de alta y baja frecuencia.*

frecuencias de la imagen (filtros en el dominio de la frecuencia). Los primeros resultan bastante sencillos de comprender y aplicar, mientras los segundos requieren un aparato matemático que excede el contenido de este manual. Baste aquí decir que se basan en las transformadas de Fourier, que convierte una imagen en una función bidimensional con dos componentes de frecuencia (horizontal y vertical), asumiendo que la variación de los ND en la imagen puede aproximarse a una función continua compleja. Aplicada la transformación, se obtienen los espectros de Fourier, que representan los componentes de fase y amplitud que definen una determinada imagen. Sobre ese espectro pueden aplicarse ciertos filtros y correcciones, especialmente valiosas cuando se trata de ruidos sistemáticos (por ejemplo un bandeado) pues aparecerán en una determinada dirección de la frecuencia (Pinilla *et al.*, 1997; Richards, 1993). Una vez realizada la modificación, puede retornarse al dominio de la imagen aplicando una transformada de Fourier inversa.

Hemos incluido los filtros digitales en este capítulo, porque las técnicas de filtraje se dirigen, directamente, al realce visual de la imagen. Al igual que las operaciones antes comentadas, pretenden mejorar la visualización de las imágenes, ya sea para eliminar valores anómalos, ya para resaltar rasgos lineales de interés. Sin embargo, a diferencia de las operaciones ya comentadas, el filtraje implica modificar los ND originales, y no sólo la forma en que se representan visualmente. En otras palabras, no se trata sólo de transformar los NV almacenados en las CLUT, sino también los ND de la imagen (aunque habitualmente se realice en memoria gráfica, para no perder los datos originales). Por tanto, si pretende abordarse una clasificación digital, las imágenes filtradas no resultan, en principio, muy convenientes, aunque refuercen visualmente rasgos de interés respecto a la imagen original.

Como hemos indicado, se suelen distinguir dos tipos de filtros de acuerdo al objetivo que se persiga. Los filtros de paso bajo *(low pass filtering)* retienen las bajas

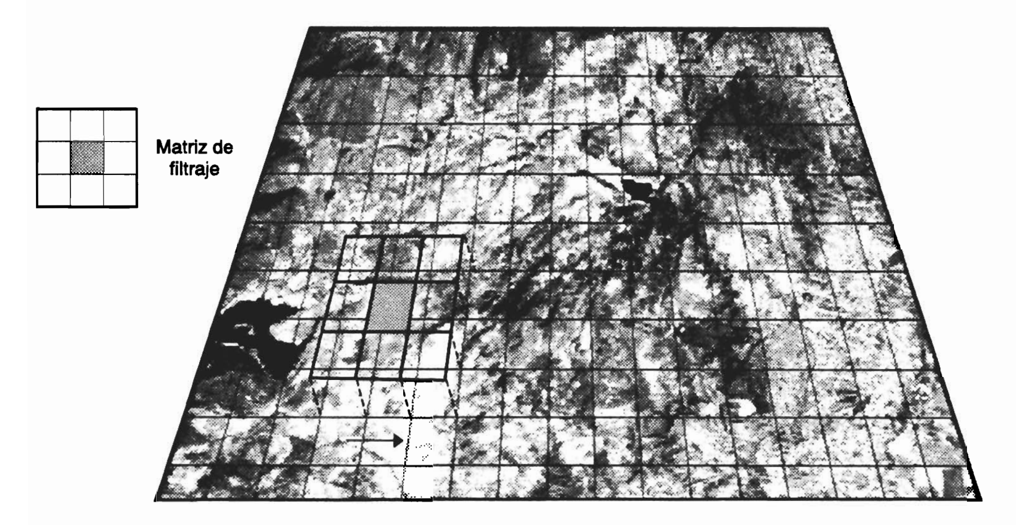


FIG. 6.18. *Diagrama sobre el funcionamiento de un filtro espacial. En cada momento, se aplica la operación sobre el píxel central (en gris) de la matriz de filtraje.*

frecuencias y, por tanto, tienden a destacar el componente de homogeneidad en la imagen, subrayando la variación regional de los ND. Por su parte, los filtros de paso alto *(high pass filtering)* se dirigen a realzar los componentes de alta frecuencia: esto es, aquellas áreas de alta variabilidad, donde el contraste espacial es intenso.

Ambos tipos de filtrado pueden abordarse con el mismo método. Si el objetivo último es poner a los píxeles de la imagen en relación con sus vecinos, ya sea para homogeneizarlos o para diferenciarlos, basta realizar una serie de operaciones aritméticas entre cada uno de ellos y sus inmediatos. La forma concreta de efectuar este proceso es aplicar sobre los ND originales una matriz móvil de coeficientes de filtraje (*CF*). Esta matriz denominada, por algunos autores, *kernel*, puede tener un tamaño variable en función del número de píxeles vecinos que queramos implicar en el proceso. Lo habitual es que se trate de una matriz de 3 × 3 CF, que se aplica sucesivamente a todos los píxeles de la imagen. Puede también disponerse de matrices de filtraje mayores, de 5 × 5, 7 × 7 píxeles, etc. Cuanto mayor sea ésta, el efecto de suavizado o realce espacial es más intenso, al considerar como vecinos un mayor número de píxeles.

En cualquier caso, la matriz de *CF* se aplica sucesivamente a la imagen original, desplazándose hacia la derecha tras calcular el nuevo valor del píxel central, que es el único que se modifica en cada desplazamiento (fig. 6.18). El siguiente cálculo, sin embargo, se obtiene de los ND originales, y no de los ND ya filtrados, con objeto de que toda la imagen tenga la misma función de filtrado.

El resultado de un filtro digital depende de los *CF* señalados por el usuario. Si éstos tienden a ponderar el valor central en detrimento de los circundantes, el píxel refuerza sus diferencias frente a los vecinos. Por el contrario, si los coeficientes favorecen a los píxeles periféricos, el central se asemejará más a los adyacentes. Obvia decir que en el primer caso nos encontraríamos ante un filtro de paso alto, mientras en el segundo sería de paso bajo.

12	14	17	24	32	34
10	18	21	35	38	40
25	15	17	27	40	43
18	16	18	24	29	39
14	16	20	20	27	36

Imagen original

1	1	1
1	2	1
1	1	1

0	0	0	0	0	0
0	17	21	29	35	0
0	17	21	28	35	0
0	18	19	25	31	0
0	0	0	0	0	0

Imagen filtrada

FIG. 6.19. *Ejemplo de filtraje digital.*

En suma, el procedimiento matemático del filtraje consiste en relacionar cada píxel con sus vecinos, de acuerdo a unos coeficientes determinados por el usuario. En el caso de una matriz de 3 × 3 CF, la fórmula para obtener el ND filtrado sería (Mather, 1998):

$$ND'_{i,j} = \frac{\sum_{p=-1,1} \sum_{q=-1,1} ND_{i+p,\,j+q}\, CF_{f+p,\,c+q}}{\sum_{p=-1,1} \sum_{q=-1,1} CF_{f+p,\,c+q}} \qquad \{6.13\}$$

donde $ND_{i,j}$ indica el ND original del píxel *i*, *j*; $ND'_{i,j}$, el ND de salida para ese mismo píxel; CF, el coeficiente de filtraje correspondiente, y *f* y *c* la fila y columna central de la matriz de filtraje. El resultado de esta fórmula se aproxima al entero más cercano. También se ha propuesto dividir el numerador por el número de píxeles de la ventana de filtrado (9 si se trata de 3 × 3), independientemente de los CF que se señalen.

El proceso abordado en un filtraje puede ilustrarse con un sencillo ejemplo. Se pretende aplicar un filtro de paso bajo a una pequeña imagen de 5 × 6 píxeles, empleando la fórmula anterior sobre un ejemplo de matriz de filtraje de 3 × 3 píxeles (fig. 6.19). La observación del resultado permite extraer algunas consideraciones de interés. En primer lugar, se constata que el área filtrada se limita a los píxeles centrales. Los píxeles de borde no se afectan por el proceso, puesto que no tienen los 8 vecinos necesarios para realizar el cálculo. Esta característica es común a cualquier filtraje, ya sea de paso alto o bajo. Obviamente, en el caso de una imagen de mayor tamaño (512 × 512 píxeles, por ejemplo), la pérdida de esos píxeles de borde no supone una grave inconveniencia. En una matriz de filtraje de 3 × 3 se pierden la primera y última fila y columna. Si empleamos matrices de mayor tamaño, la merma será más significativa: con 5 × 5, se perderían las dos primeras y últimas; con 7 × 7 las tres, etc. Otros autores prefieren aplicar algún promedio especial a estos píxeles, en lugar de igualarlos a cero.

Volviendo a nuestro ejemplo, el nuevo ND del píxel central se calcula por un promedio de los 8 vecinos, con una pequeña ponderación del valor central. Esos coeficientes se han aplicado a todos los píxeles centrales de la imagen. Por ejemplo,

el situado en la fila 3, columna 3, con un ND inicial de 17 se convierte en la nueva imagen en:

$$ND'_{3,3} = (18 + 21 + 35 + 15 + 2 \times 17 + 27 + 16 + 18 + 24) / 10 = 20{,}8 \approx 21$$

que es un valor más cercano al sector oriental de la imagen, con valores bajos. De igual forma se procede con el resto de los píxeles hasta obtener la imagen filtrada. Al terminar el proceso, el contraste global se ha reducido: mientras la desviación típica original de los 12 píxeles afectados por el filtraje es 8,91, la correspondiente a los filtrados es 6,77, lo que indica una mayor homogeneidad espacial en la nueva imagen. Un efecto más claro se hubiera obtenido al analizar una mayor superficie y/o aplicar un promedio simple en la matriz de CF. Un proceso similar se emplearía para cualquier otro tipo de filtraje.

5.4.2. *Filtros de paso bajo*

Tienen por objetivo suavizar los contrastes espaciales presentes en la imagen. En breves palabras, se trata de asemejar el ND de cada píxel al de los píxeles vecinos, reduciendo la variabilidad espacial de la escena. En términos visuales, esto supone que la imagen filtrada ofrece perfiles menos nítidos, más difuminados, como puede apreciarse en la figura 6.20, que recoge la banda 1 original y filtrada de la imagen que venimos comentando. Si comparamos ambos sectores de esta figura se observa nítidamente el efecto del filtraje. Como vemos, la imagen filtrada se muestra bastante difuminada, se han perdido la mayor parte de los contrastes espaciales, especialmente en lo que se refiere a la red vial de las áreas residenciales (A en la figura 6.20). El efecto es más evidente cuanto mayor es el tamaño de la ventana de filtraje. A cambio, la diferencia en la señal radiométrica entre estas zonas y las no urbanizadas se habrá hecho más patente, al eliminarse gran parte del contraste interno.

Este tipo de filtraje se utiliza para restaurar los errores aleatorios que pueden presentarse en los ND de la imagen, fruto de un defecto en la adquisición o recepción de los datos. Así mismo, se ha empleado para reducir la variabilidad espacial de algunas categorías, como paso previo a la clasificación. En este caso, se preten-

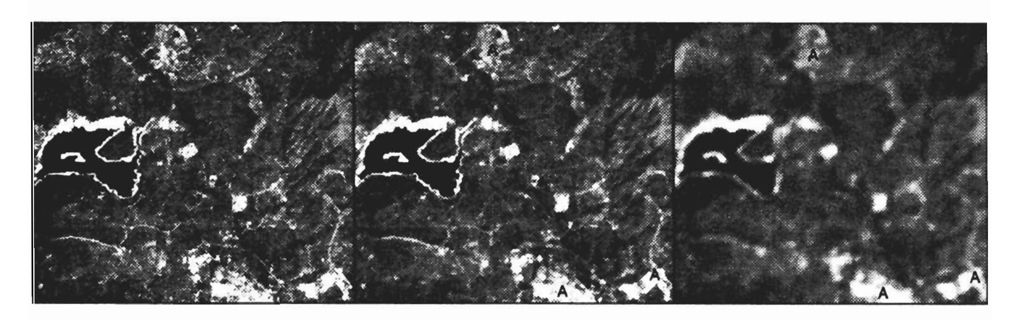


FIG. 6.20. *Filtros de paso bajo sobre una ventana de Torre100: de izda. a dcha.: original, filtro de 3 × 3; filtro de 9 × 9.*

de atenuar el denominado «ruido de la escena», producido en las zonas altamente heterogéneas en relación con la resolución espacial del sensor. El caso más claro, y el más estudiado, es el que se produce en las zonas urbanas, en donde se mezclan distintos tipos de cubierta en un reducido espacio. Para disminuir esta variabilidad espacial, se han propuesto diversos filtros de paso bajo, que tienden a homogeneizar los ND de esas zonas. El efecto de estos filtros se ha mostrado bastante eficiente de cara a la clasificación digital (Cushnie y Atkinson, 1985; Haack *et al.*, 1987). También el filtro de paso bajo puede utilizarse para obtener la «señal de fondo» cuando intentemos comparar un ND con su contexto, de cara a la detección de algún rasgo de interés que sea especialmente anómalo en su entorno, como ocurre con los fuegos activos (Flasse y Ceccato, 1996) o las nubes (Saunders y Kriebel, 1988), o para obtener la reflectividad característica de una zona de cara a corregir el efecto de adyacencia en el cálculo de la reflectividad (Richter, 1997).

El filtro de paso bajo puede obtenerse a partir de diversas matrices de filtraje. Algunas de las más habituales son:

1)

1,00	1,00	1,00
1,00	1,00	1,00
1,00	1,00	1,00

2)

1,00	1,00	1,00
1,00	2,00	1,00
1,00	1,00	1,00

3)

0,25	0,50	0,25
0,50	1,00	0,50
0,25	0,50	0,25

La primera es un simple promedio de los 9 píxeles que componen la ventana de filtraje, mientras las dos siguientes ponderan un poco el valor central para evitar una excesiva pérdida de detalle.

En los últimos años se ha aplicado con buen rendimiento otro tipo de filtraje, basado sobre la mediana en lugar de la media. El filtro mediano consiste en sustituir el ND del píxel central por la mediana de los ND correspondientes a los píxeles vecinos. Su interés se corresponde con el propio de la mediana como medida de centralidad, ya que es menos sensible a los valores extremos y entraña una menor modificación de los datos que la media aritmética; de ahí que se haya recomendado su empleo dentro de las técnicas de análisis exploratorio de datos (Shaw y Wheeler, 1985). En el contexto del ADI, se ha empleado para eliminar valores anómalos aislados, fruto de ruidos aleatorios en la adquisición de los datos. Preserva mejor los contornos que el filtro promedio, pero demanda un mayor volumen de cálculo. Se ha aplicado con éxito para reducir el moteado brillante (*speckle*) de las imágenes radar (Blom y Daily, 1982).

5.4.3. *Filtros de paso alto*

Este tipo de filtros pretende aislar los componentes de alta frecuencia en una imagen. En términos espaciales, esto supone remarcar digitalmente los contrastes espaciales entre píxeles vecinos, enfatizando los rasgos lineales presentes en la imagen, como carreteras, parcelas o accidentes geológicos. En definitiva, se inten-

ta reforzar los contornos entre áreas homogéneas, evidenciando cualquier discontinuidad.

Varios métodos pueden conseguir este objetivo. El más sencillo pasa por restar de la imagen original la obtenida por un filtro de paso bajo. La razón es bastante obvia: si lo que se pretende es aislar los componentes de alta frecuencia (alta variabilidad), basta restar de la imagen original aquellos correspondientes a la baja frecuencia, con lo que sólo quedarían los requeridos, que se añadirían a la imagen original. En suma:

$$ND'_{i,j} = ND_{i,j} + (ND_{i,j} - ND_{L,i,j}) \quad \{6.14\}$$

donde ND′ corresponde al ND de salida, ND al original, y ND_L al resultado de un filtro de paso bajo.

Más común es, sin embargo, emplear matrices de filtraje, similares a las anteriormente analizadas. En este caso, los CF se disponen de tal modo que se refuerza el contraste entre el píxel central y los vecinos. Dos matrices frecuentemente utilizadas son:

4)

–1	--1	–1
–1	9	–1
–1	–1	–1

5)

0	–1	0
–1	4	–1
0	–1	0

ambas se derivan del análisis de gradientes de cambio en la imagen. El segundo filtro, denominado Laplaciano, se recomienda para el realce de rasgos lineales en áreas urbanas o rasgos geológicos.

Puede analizarse la aplicación de este filtro sobre la imagen Torre100 en la figura 6.21. El proceso implica un mayor realce de los abundantes rasgos lineales de la imagen: carreteras y líneas de ferrocarril, viario urbano, etc. que aparecen con color claro, quedando las áreas homogéneas en oscuro. Puede abordarse un filtro me-

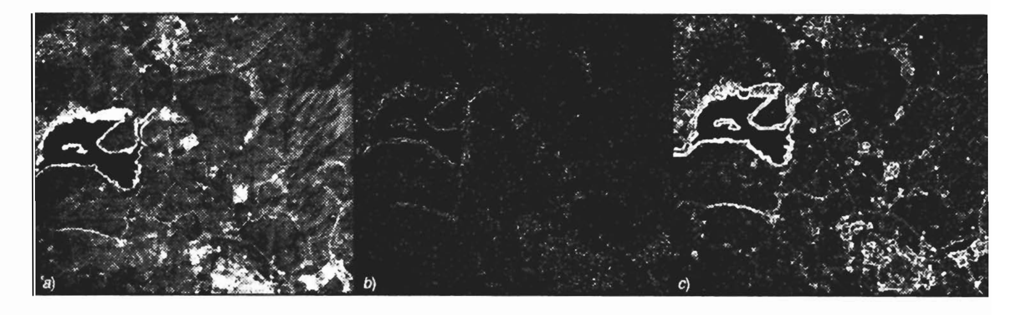


FIG. 6.21. *Filtros de paso alto sobre una ventana de Torre100: (a) original, (b) filtro laplaciano de 3 × 3; (c) filtro de Sobel.*

nos severo incrementando el valor del píxel central, lo que permitirá conservar mejor la radiometría original de la imagen.

Para reforzar aún más las fronteras entre categorías, puede ser recomendable aplicar filtros no lineales, que se dirigen a realzar los gradientes de cambio en la imagen. Uno de los más empleados es el denominado detector de bordes de Sobel (Gonzalez y Wintz, 1977), que realza la variación entre filas y columnas de la matriz de filtraje. En una ventana de 3 × 3 píxeles, el ND del píxel central se calcula de la forma siguiente:

$$ND'_{i,j} = \sqrt{C^2 + F^2} \qquad \{6.15\}$$

donde:

$$C = (ND_{i-1,\,j+1} + 2\,ND_{i,\,j+1} + ND_{i+1,\,j+1}) - (ND_{i-1,\,j-1} + 2\,ND_{i,\,j-1} + ND_{i+1,\,j-1})$$

y

$$F = (ND_{i-1,\,j-1} + 2\,ND_{i-1,\,j} + ND_{i-1,\,j+1}) - (ND_{i+1,\,j-1} + 2\,ND_{i+1,\,j} + ND_{i+1,\,j+1})$$

El efecto de este filtro sobre nuestra imagen puede observarse en la figura 6.21*c*. Se remarcan con claridad las principales vías de comunicación, los límites del embalse y de los núcleos residenciales, mientras quedan en tonos oscuros únicamente los sectores de mayor homogeneidad. El resultado parece algo más rígido que el filtro laplaciano, pero recoge mejor los gradientes de cambio en este sector de la imagen.

Además de los filtros arriba expuestos, una forma sencilla de realzar los bordes sería realizar una copia de la imagen, desplazarla una fila y/o columna sobre la original y restar ambas. Aquellos píxeles que ofrezcan un valor cercano a 0 indicarán áreas de escasa variación, mientras cuanto mayor sea esta diferencia, mayor será también el contraste especial entre píxeles vecinos. Asimismo puede definirse una dirección de contraste, hacia valores superiores o inferiores según sea negativa o positiva la diferencia. Se han desarrollado otros métodos de realce de bordes para aplicaciones específicas, como son la detección de lineamientos (Moore y Waltz, 1983), el realce de plumas de agua (Jensen, 1996, pp. 162-165), o la delimitación de calles en una ciudad (Gong y Howarth, 1990).

Las matrices de filtraje antes comentadas permiten subrayar cualquier rasgo fronterizo de la imagen, independientemente de su orientación. La misma técnica puede emplearse para construir filtros direccionales, con el propósito de reforzar aquellas líneas que sigan determinadas orientaciones. Basta disponer adecuadamente los CF, distribuyéndolos en sectores de la matriz. Algunos ejemplos de matrices de filtraje para conseguir este análisis direccional son:

6)

Norte		
1	1	1
1	–2	1
–1	–1	–1

7)

Sur		
–1	–1	–1
1	–2	1
1	1	1

8)

Este		
–1	1	1
–1	–2	1
–1	1	1

9)

Oeste		
1	1	–1
1	–2	–1
1	1	–1

10)

Sureste		
–1	–1	1
–1	–2	1
1	1	1

11)

Noroeste		
1	1	1
1	–2	–1
1	–1	–1

12)

Suroeste		
1	–1	–1
1	–2	–1
1	1	1

13)

Noreste		
1	1	1
–1	–2	1
–1	–1	1

Conviene indicar que el nombre de estas matrices es consecuencia de la dirección del contraste que señalan, y no de la dirección que están realmente realzando, que es precisamente la perpendicular. Por ejemplo, la matriz norte estaría reforzando líneas situadas este-oeste (en concreto la frontera norte de esas líneas), mientras la este refuerza el borde oriental de las líneas norte-sur.

La figura 6.22 recoge la aplicación de estos filtros direccionales al mismo sector de la imagen que venimos comentando. Son patentes las diferencias entre las tres direcciones que estamos realzando (especialmente claro el contraste entre el filtro norte y el este), lo que permite analizar patrones direccionales referidos a vías de comunicación o rasgos geológicos de interés.

6. Correcciones de la imagen

Con este nombre se indican aquellos procesos que tienden a eliminar cualquier anomalía detectada en la imagen, ya sea en su localización, ya en la radiometría de los píxeles que la componen. Estas operaciones tienden a disponer los datos en la forma más cercana posible a una adquisición idónea, por ejemplo, situándolos sobre su posición geográfica correcta (georreferenciación), o reconstruyendo la radiancia detectada por el sensor a partir de los ND de la imagen. No obstante, el término corrección, que da título a este epígrafe, conviene manejarlo con ciertos matices, puesto que no todas las operaciones aquí incluidas pueden calificarse propiamente como soluciones a defectos de adquisición de los datos. De hecho, la georreferenciación cartográfica de la imagen implica introducir una nueva deformación, ya que no es posible representar coordenadas esféricas sobre un plano con total precisión. Sin embargo, esta operación es necesaria si se quiere que los resultados del análisis tengan validez cartográfica o puedan conectarse con otros datos auxiliares almacenados en un SIG.

Hemos incluido en este epígrafe dos grandes temas, las correcciones de la radiometría de la imagen, es decir, las transformaciones de los ND para solventar los

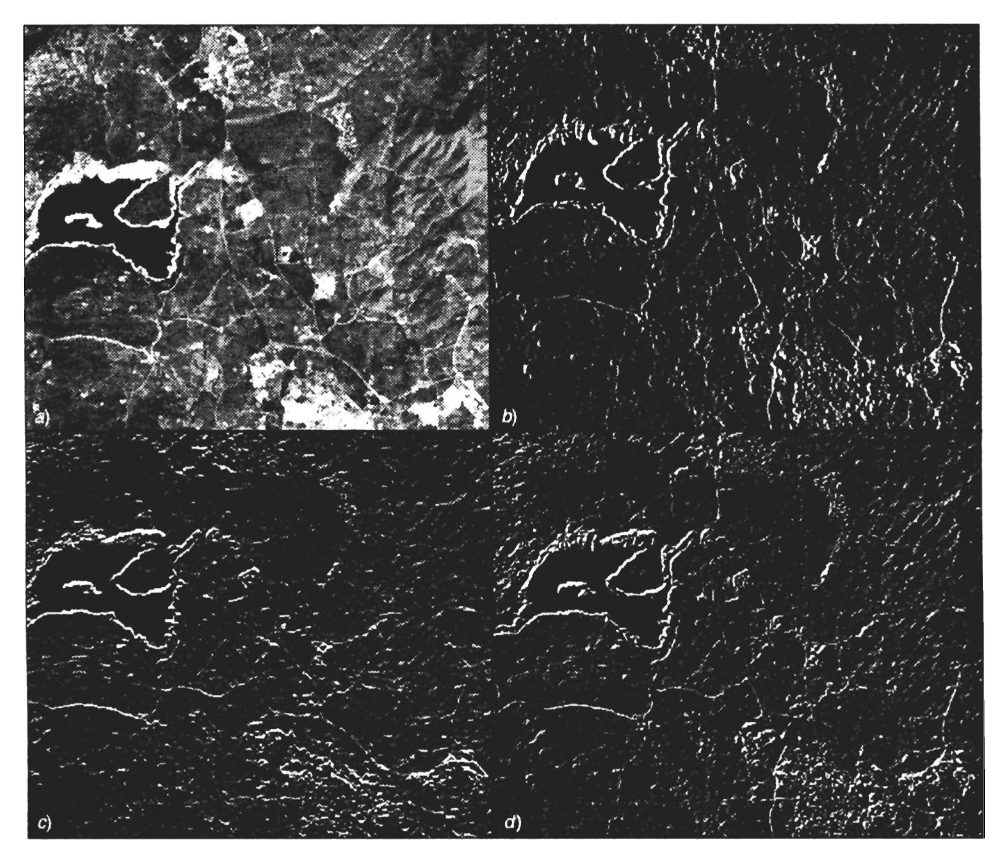


FIG. 6.22. *Filtros direccionales sobre la imagen Torre100:* (a) *original;* (b) *filtro este;* (c) *filtro norte;* (d) *filtro sureste.*

problemas de adquisición, y las correcciones geométricas o georreferenciación. Comentaremos antes las principales fuentes de error que puede implicar la captura de la imagen.

6.1. FUENTES DE ERROR EN UNA IMAGEN ESPACIAL

Cualquier imagen adquirida por un sensor remoto, ya sea aéreo o espacial, presenta una serie de alteraciones radiométricas y geométricas debidas a muy variados factores. Esto explica que la imagen finalmente detectada no coincida exactamente con la radiancia-posición-forma-tamaño de los objetos que incluye. En el caso concreto de las imágenes espaciales, las deformaciones más frecuentes pueden agruparse en cuatro apartados (Bernstein, 1978; Mather, 1998):

1. *Distorsiones originadas por la plataforma.* Pese a la gran estabilidad de un satélite de observación, muy superior a la que ofrece un avión, pueden producirse pequeñas variaciones en la altitud de su órbita, en la velocidad, o en la orienta-

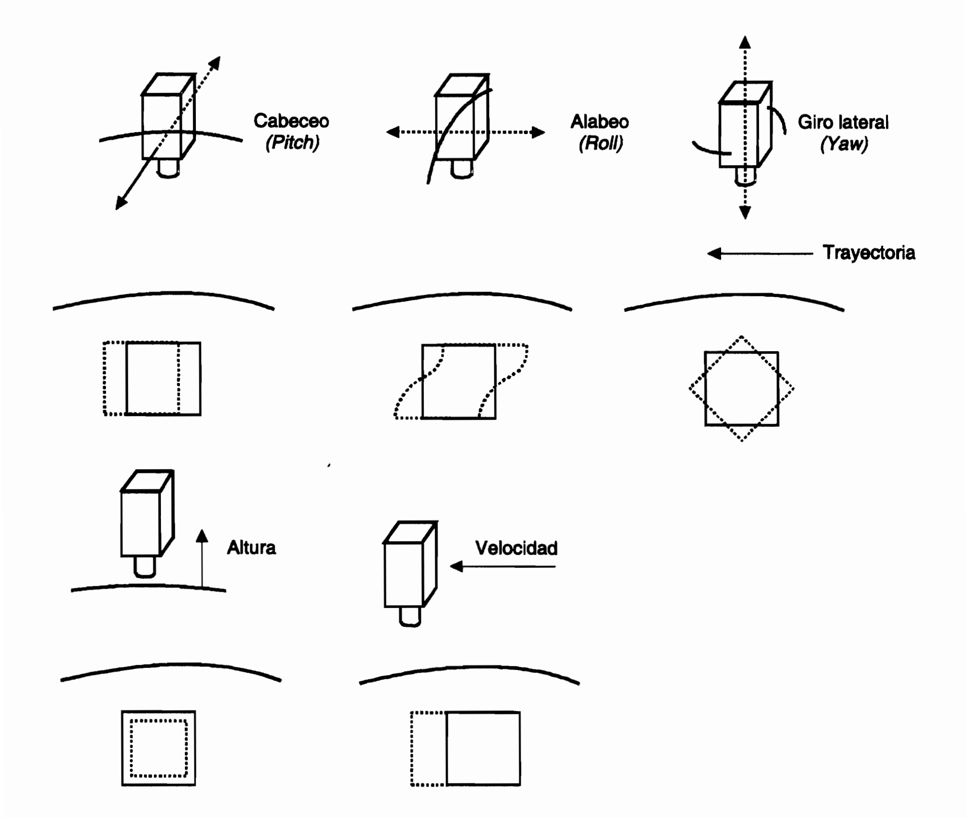


FIG. 6.23. *Algunas fuentes de error geométrico en una imagen espacial.*

ción de cualquiera de sus tres ejes: alabeo *(roll)*, cabeceo *(pitch)*, giro lateral *(yaw)*. En el primer caso, se producen cambios en la escala de la imagen, mientras, en el segundo, distorsiones de distinto tipo en su geometría de adquisición (fig. 6.23). Ambos factores pueden considerarse como no sistemáticos, puesto que aparecen de forma esporádica y son, por ello, difícilmente predecibles y complejos de modelar (Welch y Usery, 1984).

2. *Distorsiones provocadas por la rotación terrestre.* Teniendo en cuenta la altitud orbital y el área abarcada por el sensor, el efecto de rotación de la tierra puede aparecer claramente en la imagen. Por ejemplo, en el caso del MSS del satélite Landsat, cada imagen de 185 × 185 km se adquiría, en latitudes medias, en unos 28 segundos. En este lapso de tiempo, desde la primera hasta la última línea de barrido, la Tierra se desplaza sensiblemente (unos 8 km), lo que causa, junto a la propia inclinación de la órbita, una orientación de la imagen noreste-suroeste. También provocada por la superficie terrestre es la variación del tamaño del píxel por efecto de la curvatura terrestre.

3. *Distorsiones provocadas por el sensor.* Varios factores de distorsión geométrica y radiométrica pueden deberse al propio funcionamiento del sensor. Como ya vimos, los sensores de barrido electrónico realizan una exploración perpendicular a la trayectoria del satélite, gracias a un espejo oscilante que envía la radiancia

registrada a una cadena de detectores sólidos. Este movimiento puede alterarse por anomalías del sensor, provocando un efecto de barrido no lineal o cambios en el intervalo de recogida de información, lo que implica transformar la resolución efectiva de la imagen.

Un segundo efecto debido al sensor se relaciona con el ángulo de barrido o campo de visión global. En el caso de sensores con un ángulo ancho de barrido (AVHRR o MODIS, por ejemplo), se presenta una distorsión panorámica amplia, tanto mayor cuanto más nos alejamos del nadir. En consecuencia, el tamaño del píxel varía sensiblemente desde el centro hacia los extremos de la imagen (en el caso del AVHRR, con un tamaño de píxel en el nadir de 1,1 × 1,1 km, se puede llegar en los extremos a un tamaño de 2,4 × 6,5 km) (Goward *et al.*, 1991). Esto implica, junto a las deformaciones geométricas, una notable variación en las perturbaciones debidas a la atmósfera, ya que el espesor óptico cambia del nadir a los extremos. Cuando se trata de sensores con menor campo de visión (ETM o HRVIR), estos efectos son de menor calibre.

Otro problema frecuente que plantea el sensor es la falta de calibración entre detectores. En los sensores de barrido la exploración se realiza en varias líneas simultáneamente, por lo que requieren varios detectores por banda. Resulta muy importante que todos ellos traduzcan uniformemente la señal detectada, con objeto de que la misma radiancia recibida no se codifique en ND distintos. En ocasiones ese ajuste entre detectores se deteriora, provocándose un efecto de bandeado en la imagen final, especialmente perceptible en las zonas de baja radiancia (sombras, superficie marina). Para el caso de los equipos de exploración por empuje (3.3.3), el problema de calibración es aún mayor, ya que cuentan con un gran número de detectores por línea (6.000 para la banda pancromática del HRV). En este caso, un mal ajuste supondría un bandeado longitudinal en la imagen resultante. Más evidente todavía resultan los fallos momentáneos de alguno de los detectores, ya sea en la emisión, ya en la recepción de la señal. Esto provoca la pérdida de una serie de líneas o píxeles en la imagen final.

4. *Distorsiones provocadas por la atmósfera.* Como ya se comentó, los distintos elementos que componen la atmósfera causan una modificación de la radiancia original proveniente de la superficie terrestre. El efecto más importante es el de dispersión del flujo reflejado desde la superficie, a consecuencia de la presencia de aerosoles, gases y vapor de agua. Este efecto implica un aumento de la señal recibida por el sensor y es más sensible en las longitudes de onda cortas, que tienden a presentar un menor contraste entre coberturas de similar comportamiento radiométrico.

Algunos de estos problemas se solventan rutinariamente en los centros encargados de la recepción o venta de las imágenes. Otros, sin embargo, persisten, haciendo precisas una serie de técnicas para subsanarlos. Por ejemplo, las correcciones atmosféricas son vitales para modelar parámetros físicos a partir de la imagen (6.6.2.3), generar índices espectrales (7.1.2) o abordar estudios multi-temporales (7.3). En este último caso, también son necesarias las correcciones geométricas, así como siempre que se pretenda relacionar la imagen con algún tipo de información auxiliar.



CORRECCIONES RADIOMÉTRICAS

Este es un término muy genérico, que designa aquellas técnicas que modifican los ND originales, con objeto de acercarlos a los que habría presentes en la imagen caso de una recepción ideal. Dentro de este concepto hemos incluido el tratamiento de los problemas radiométricos derivados del mal funcionamiento del sensor, junto a la obtención de magnitudes físicas y corrección atmosférica de los datos.

6.2.1. *Restauración de líneas o píxeles perdidos*

Un mal funcionamiento del sensor o de la antena receptora de la imagen puede llevar a que ésta aparezca con algunas líneas o píxeles perdidos. En una visualización, la imagen presentaría una serie de líneas anómalas (negras o blancas), o incluso una serie de píxeles aislados de aspecto muy contrastado con los vecinos (efecto conocido como de «sal y pimienta»). En ambos casos, se trata de información irreparablemente perdida. No puede restaurarse lo que nunca se obtuvo: por tanto, los procesos de corrección se dirigen aquí a mejorar artificialmente el aspecto visual de la imagen, facilitando su posterior interpretación.

La forma más lógica de estimar los ND de estos píxeles erróneos se basa en los ND de los píxeles vecinos. De acuerdo al conocido fenómeno de la auto-correlación espacial, muchas variables geográficas tienden a presentar una fuerte asociación en el espacio (Campbell, 1981; Cliff y Ord, 1973). La probabilidad de que aparezca una precipitación similar a la de una determinada estación, por ejemplo, es muy alta en estaciones cercanas, reduciéndose según nos alejamos de aquélla. De igual forma, los valores de radiancia provenientes de una parcela de la superficie terrestre tienden a estar positivamente correlacionados con los provenientes de parcelas vecinas. Por ello, parece razonable estimar los ND de las líneas perdidas a partir de los ND de las inmediatas. Este criterio de vecindad puede introducirse de distintas formas. La más sencilla es sustituir el ND de cada línea / píxel por el de los precedentes:

$$ND_{i,j} = ND_{i-1,j} \qquad \{6.16\}$$

donde $ND_{i,j}$ corresponde al nivel digital del píxel de la línea **i** (la defectuosa) y columna, *j*, y $ND_{i-1,j}$, indica el nivel digital del píxel situado en la línea precedente. También podría incluirse $i + 1$, para sustituir las líneas defectuosas por las posteriores.

Un segundo método de sustitución promedia los valores de las líneas anterior y posterior a la defectuosa. Esto es:

$$ND_{i,j} = \text{ENT}\left\{(ND_{i-1,j} + ND_{i+1,j})/2\right\} \qquad \{6.17\}$$

en donde ENT { } indica que el resultado de la operación debe convertirse en el número entero más cercano. De acuerdo con Mather (1998), este segundo método resulta más arriesgado que el primero, sobre todo en aquellos casos en donde es menos claro asumir una auto-correlación espacial.

Un tercer método de recuperar la información perdida utiliza una banda auxiliar, altamente correlacionada con la que presenta problemas. A partir de esta banda auxiliar, se estima el valor de los píxeles defectuosos de la forma siguiente (Bernstein *et al.*, 1984):

$$\mathrm{ND}_{i,j,k} = (s_k / s_r)\left\{\mathrm{ND}_{i,j,r} - (\mathrm{ND}_{i+1,j,r} + \mathrm{ND}_{i-1,j,r})/2\right\} + \\ + (\mathrm{ND}_{i+1,j,k} + \mathrm{ND}_{i-1,j,k})/2 \qquad \{6.18\}$$

donde s_k y s_r son las desviaciones típicas de la banda a restaurar k y la banda auxiliar r, respectivamente. Al igual que en el caso anterior, el resultado debería convertirse al valor entero más cercano.

En cualquiera de los tres algoritmos {6.16 a 6.18}, se asume que las líneas defectuosas ya han sido localizadas. Esto puede ser una tarea trivial en algunos casos, pero en otros resulta bastante complejo. Para ello, puede emplearse un método de búsqueda automática, que parte de comparar la media aritmética de cada línea con la de las líneas anterior y posterior. Si difiere de ellas significativamente —esto es, por encima de un determinado umbral—, se realiza un estudio más detallado de los ND que la componen, con objeto de detectar valores anómalos (0 o 255, por ejemplo). Si éstos aparecen, puede considerarse que aquella línea está afectada por algún tipo de error, y aplicarse sobre ella uno de los algoritmos previamente tratados.

Lo mismo cabe decir respecto a píxeles que muestren un valor anómalo, fruto de un error en la adquisición o recepción de los datos. En estos casos, será aún más complicado localizar visualmente los píxeles erróneos. Lillesand y Kiefer (2000) proponen un método de búsqueda automática, basado en detectar aquellos píxeles que cuenten con un ND significativamente más alto o más bajo que el promedio de sus vecinos (calculado, normalmente, a partir de una ventana móvil de 3 × 3 píxeles). Caso de que el ND del píxel central de dicha ventana exceda, por encima o debajo de un cierto umbral, al ND medio de los píxeles vecinos, se sustituye por éste.

6.2.2. *Corrección del bandeado de la imagen*

En algunas imágenes obtenidas por equipos de barrido secuencial (sobre todo en los primeros sensores Landsat-MSS), se observa un bandeado de la imagen, especialmente perceptible en las zonas de baja radiancia (láminas de agua). Este bandeado, conocido como *striping* en la terminología anglosajona, se debe a un mal calibrado entre los detectores que forman el sensor; esto es, a que alguno de ellos codifique la radiancia que recibe en ND distintos a los demás. Los equipos de barrido multiespectral exploran varias líneas simultáneamente a cada oscilación del espejo. En el caso de que los detectores presenten inconsistencias, aparecerán en la imagen unas líneas más oscuras o claras que el resto (fig. 6.24). El efecto, además, es periódico, ya que cada detector registra 1 de cada p líneas, siendo p el número de detectores por banda. En el caso del sensor MSS, se registraban 6 líneas simultáneamente gracias a los 6 detectores, mientras este número se elevó a 16 para el TM. Para

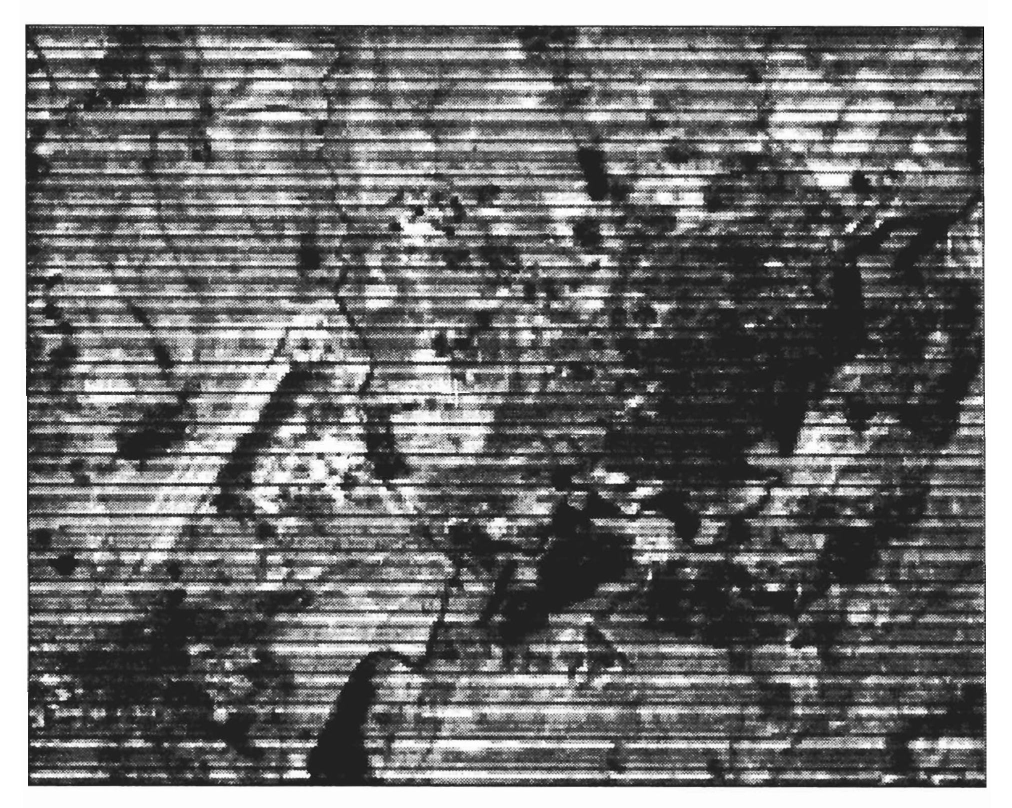


FIG. 6.24. *Efecto de bandeado en la banda térmica de una imagen ETM+ sobre Alcalá de Henares.*

las imágenes tomadas por sensores de empuje (3.3.3), la calibración puede llegar a ser aún más problemática, ya que para explorar simultáneamente una franja de terreno amplia, el sensor cuenta con una cadena de detectores muy numerosa (varios miles, habitualmente). En este caso, una falta de calibración entre detectores se observará en un bandeado vertical, ya que cada columna de la imagen se adquiere por un detector distinto. La figura 6.25 recoge un claro ejemplo de este efecto, en este caso sobre una imagen tomada por el sensor ALI (a bordo del satélite EO-1) sobre la región argentina de Mendoza. Los coeficientes de calibración son específicos para cada columna de la imagen.

Para ajustar digitalmente la señal detectada por cada uno de los detectores, se asume que todos ellos, caso de estar bien calibrados, tenderían a presentar similares histogramas. Basta, por tanto, recomponer el histograma de cada detector, calculando la frecuencia de los *p* grupos de líneas independientemente (fig. 6.26). Por ejemplo, caso de trabajarse sobre una imagen MSS, con seis detectores por banda, se calcula, por un lado, el histograma de las líneas 1, 7, 13, 19, 25..., esto es, las recogidas por el primer detector; por otro, el correspondiente a las líneas 2, 8, 14, 20, 26... (segundo detector), y así sucesivamente hasta completar los seis detectores.

El paso siguiente intenta ajustar estos histogramas a otro que se elija como re-

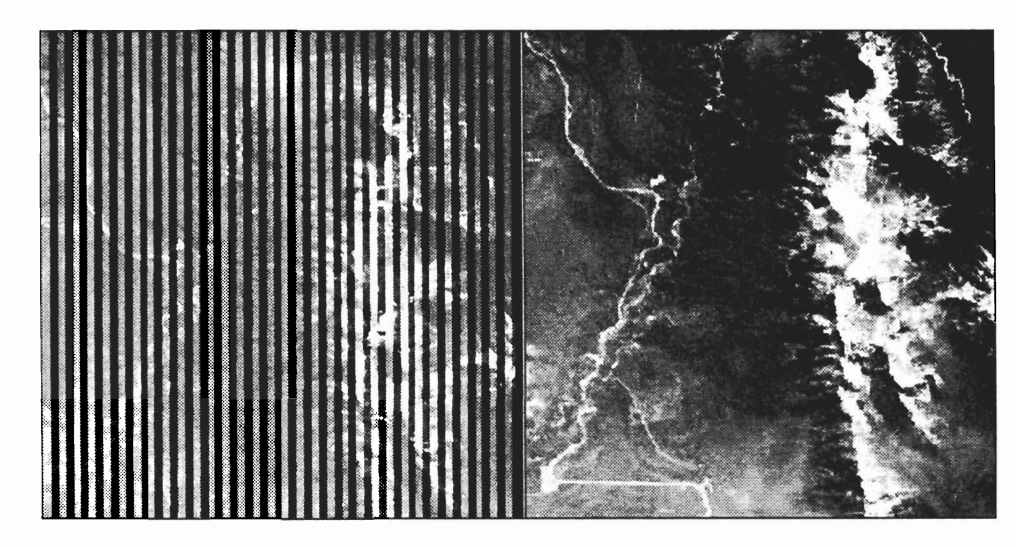


FIG. 6.25. *Problemas de calibrado en una imagen ALI. A la derecha los ND originales, a la izquierda los valores de radiancia calibrados. La imagen se adquirió sobre la provincia de Mendoza (Argentina) el 27 de marzo de 2001. (Cortesía Ruiliang Pu, U.C. Berkeley.).*

ferencia. Lo más habitual es que el histograma de referencia sea el del conjunto de la imagen, formado por todas las líneas que la componen. La forma más sencilla de realizar el ajuste se basa en aplicar unos coeficientes lineales (sesgo y ganancia) a los histogramas de cada detector, con objeto de igualar sus medias y desviaciones típicas con las del histograma de referencia. Aunque existen otros procedimientos no lineales (considerando el histograma acumulativo), el método lineal ofrece, en la mayor parte de los casos, buenos resultados.

Su proceso parte de calcular la media y desviación típica de cada histograma

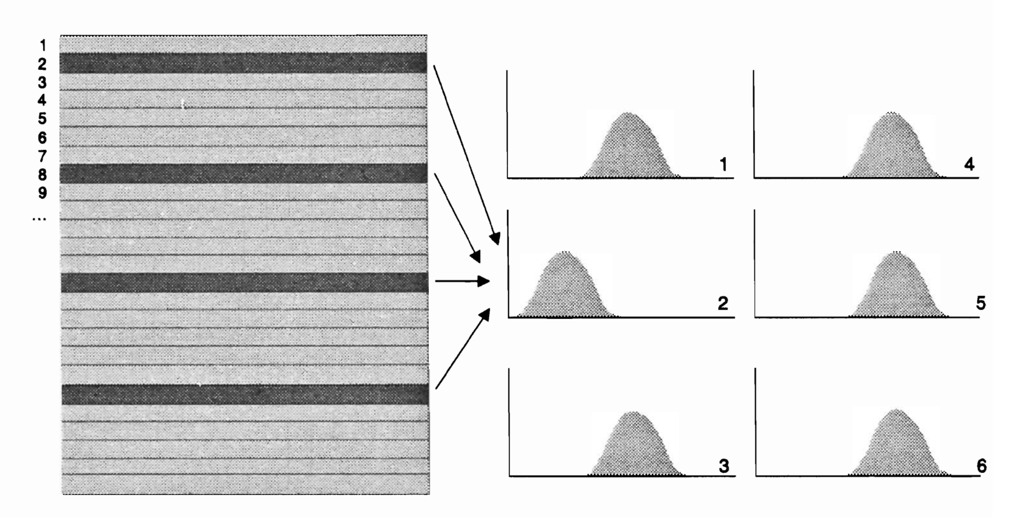


FIG. 6.26. *Para corregir el bandeado de la imagen se calculan histogramas parciales de cada conjunto de* p *líneas de la imagen, siendo* p *el número de detectores (adaptado de Campbell, 1996).*

parcial; esto es, del correspondiente a los píxeles codificados por un determinado detector. Posteriormente, para ajustar estos valores a los encontrados para el histograma de referencia basta aplicar:

$$b_i = s / s_i \qquad \{6.19\}$$

y

$$a_i = \overline{\mathrm{ND}} - b_i \overline{\mathrm{ND}}_i \qquad \{6.20\}$$

donde s y s_i indican las desviaciones típicas del histograma de referencia y parcial, respectivamente; $\overline{\mathrm{ND}}$ y $\overline{\mathrm{ND}}_i$, los ND medios para ambos, y a_i y b_i los coeficientes de ajuste. A partir de estos coeficientes puede calcularse el valor corregido, aplicando una sencilla función:

$$\mathrm{ND}'_{i,j} = a_i + b_i \mathrm{ND}_{i,j} \qquad \{6.21\}$$

en donde el ND de salida se calcula a partir de aplicar unos coeficientes de ajuste al ND de entrada. Para reducir el volumen de cálculos, este algoritmo suele aplicarse a partir de una técnica muy similar a las tablas de color (CLUT) que vimos anteriormente.



6.2.3 *Cálculo de reflectividades*

La conversión de los ND almacenados en una imagen original a variables físicas es un paso previo que resulta de gran utilidad en múltiples fases de la interpretación de imágenes, ya que permite trabajar con variables físicas de significado estándar, comparables en un mismo sensor a lo largo del tiempo, entre distintos sensores y entre la teledetección espacial y otros métodos de detección de energía electromagnética. El primer aspecto resulta relevante cuando pretendamos abordar tareas de detección de cambios (7.3); el segundo es clave para integrar información espectral procedente de distintos equipos (por ejemplo, en tareas de fusión de imágenes, 7.1.7); Finalmente, el tercero es crítico si queremos comparar nuestros datos con los obtenidos por teledetección aérea o radiómetros de campo (por ejemplo, con las librerías espectrales que vimos en 2.5.5).

Naturalmente podemos afirmar que esa información ya está contenida en los ND originales, pero conviene considerar que sólo de modo relativo. En otras palabras, la relación numérica está circunscrita a cada banda de la imagen. Ahí sí es cierto que a mayor ND, mayor reflectividad, pero no sirve para comparar bandas entre sí. Un mayor ND entre dos bandas, no indica necesariamente mayor reflectividad, ni en imágenes de distintas fechas o sensores. Por el contrario, la reflectividad o temperatura son variables físicas comparables entre lugares y fechas, lo que hace más sólida la interpretación de los datos, garantiza la compatibilidad multitemporal y el análisis integrado con imágenes de distintos sensores, lógicamente siempre que abarquen las mismas bandas del espectro.

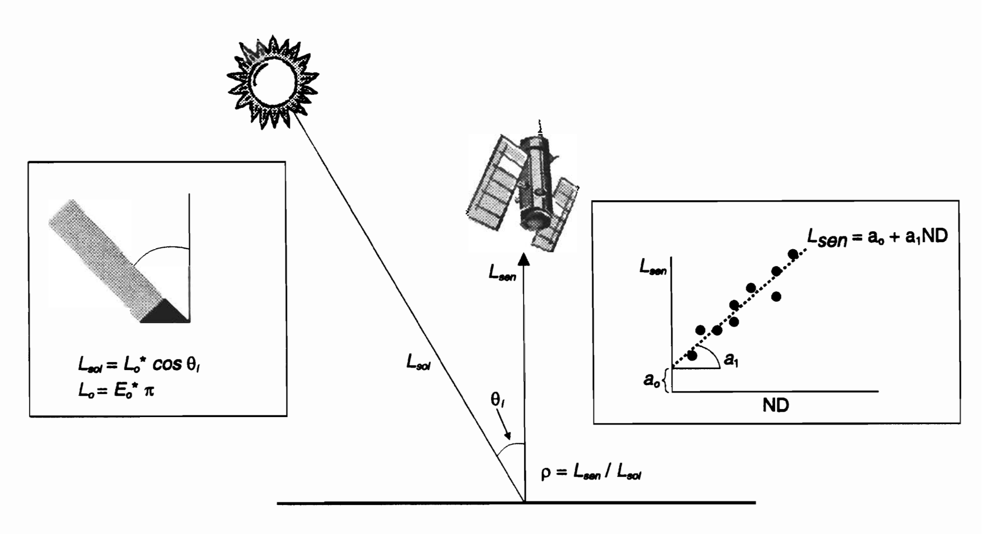


FIG. 6.27. *Cálculo simplificado de la reflectividad.*

La obtención de esas variables requiere resolver satisfactoriamente la acción de varios factores. Algunos hacen referencia al propio sensor (calibrado de las radiancias), para lo que es imprescindible contar con información de la entidad que lo gestiona, otras a las condiciones de observación (ángulos de iluminación y adquisición), y otras a elementos del ambiente (efecto atmosférico y topográfico, iluminación procedente de otras cubiertas). Intentaremos analizar estos diversos factores, proponiendo tratamientos que, dentro de una cierta simplicidad, permitan solventar eficazmente sus efectos.

6.2.3.1. Reflectividad aparente: modelo simplificado

Definimos en el capítulo 2 la reflectividad como la relación entre la energía reflejada y la incidente. Varía, por tanto, entre 0 (superficie perfectamente absorbente) y 1 (superficie perfectamente reflectora). Como también sabemos, la reflectividad de una cubierta depende de sus características físicas y químicas, así como de las condiciones de observación. Además no es constante, sino que se modifica en las distintas bandas del espectro, por lo que debemos añadirle el calificativo de espectral, acotando su medida a un determinado rango de longitudes de onda. Precisamente, en el análisis de cómo varía la reflectividad espectral de una cubierta encontramos la raíz para poder discriminarla.

De acuerdo a la definición antes recordada, para conocer la reflectividad de una superficie es preciso relacionar dos magnitudes: la energía reflejada y la incidente (fig. 6.27). A partir de los datos medidos por el sensor podemos obtener la primera, ya que la radiancia espectral medida por éste es consecuencia de la reflexión de la radiación solar procedente del suelo. Esa medición se codifica a un valor numérico (el ND), de acuerdo a unos coeficientes de calibración específicos para cada sensor. Ya que estos coeficientes son conocidos, puede realizarse el proceso inverso, obteniendo los valores de radiancia espectral detectada por el sensor a partir de los ND:

$$L_{sen,k} = a_{0,k} + a_{1,k}\mathrm{ND}_k \qquad \{6.22\}$$

donde $L_{sen,k}$, corresponde a la radiancia espectral recibida por el sensor en la banda k (en W m^{-2} sr^{-1} mm^{-1}); $a_{0,k}$ y $a_{1,k}$ son los coeficientes de calibración para esa banda, y ND_k, corresponde al nivel digital de la imagen en la misma banda. Estos coeficientes de calibrado suelen incluirse en la cabecera de la imagen. En la tabla 6.5 aparecen los correspondientes a los sensores TM y ETM+. Estos datos se han actualizado recientemente, tras revisar las calibraciones previas y realizar una calibración cruzada entre los dos sensores [Chander, 2004 #5085].

Por otro lado, la radiancia que llega al sensor —asumiendo que la superficie terrestre tiene un comportamiento lambertiano— es una función de la irradiancia solar, la reflectividad de la cubierta y las condiciones de adquisición (fig. 6.27):

$$L_{sen,k} = \frac{E_{0,k} \cos\theta_i \, \rho^*_k}{D\pi} \qquad \{6.23\}$$

donde $E_{0,k}$ es la irradiancia solar en el techo de la atmósfera (para esa banda del espectro), conocida a partir de las tablas solares (tabla 6.5); ρ^*_k es la reflectividad aparente de la cubierta en esa banda k; θ_i es el ángulo cenital del flujo incidente, formado por la vertical y los rayos solares que es el complementario del ángulo de elevación solar, que se incluye en la cabecera de la imagen, y D es el factor corrector de la distancia Tierra-Sol, calculado como:

$$D = (1 + 0{,}01674\,(sen(2\pi(J - 93{,}5)/365)))^2 \qquad \{6.24\}$$

donde J indica el número de día del año y el seno se asume en radianes. Este factor varía entre 0,983 (3 de enero) en el perihelio y 1,017 (4 de julio) en el afelio.

TABLA 6.5. *Parámetros para la conversión a reflectividades de imágenes Landsat**

		Landsat-5 TM			*Landsat-7 ETM+*	
Banda	$E_{0,k}$ *(W m^{-2} μm^{-1})*	$a_{0,k}$	$a_{1,k}$[1]	$a_{1,k}$[2]	$a_{0,k}$	$a_{1,k}$
1	1.957	–1,52	0,602	0,763	–6,2	0,786
2	1.829	–2,84	1,175	1.443	–6,0	0,817
3	1.557	–1,17	0,806	1.039	–4,5	0,639
4	1.047	–1,51	0,815	0,873	–4,5	0,635
5	219,3	–0,37	0,108	0,120	–1,0	0,128
7	74,52	–0,15	0,057	0,065	–0,35	0,044

1. Anterior al 5 de mayo de 2003.
2. Posterior al 5 de mayo de 2003.
* Los valores de irradiancia solar se han tomado de Price (1987). Los parámetros de calibración se han tomado de Chander *et al.* (2004).

A partir de la fórmula anterior, puede calcularse la reflectividad aparente como:

$$\rho_k^* = \frac{D\pi L_{sen,k}}{E_{0,k} \cos \theta_i} \qquad \{6.25\}$$

En síntesis entonces, para convertir ND a reflectividades se requiere, en primer lugar, transformarlos a valores de radiancia ($L_{sen,k}$), a partir de los coeficientes de calibrado del sensor, para luego obtener de esta radiancia la reflectividad (ρ_k^*), conociendo la irradiancia solar (E_0) y la fecha de adquisición de la imagen (de la que se estima D y el ángulo cenital θ_i).

Como puede observarse en la figura 6.28, la transformación de ND a reflectividad aparente únicamente modifica las diferencias de calibración entre bandas de la misma imagen y cambia la escala de medición a un parámetro físico, pero no permite corregir efectos atmosféricos, o aquellos debidos a la influencia de cubiertas vecinas, a los ángulos de observación o las condiciones de iluminación. En definitiva, esta reflectividad aparente asume que la observación se realiza para una atmósfera transparente, verticalmente, sobre suelo plano y superficies perfectamente lambertianas.

Como ya indicamos en el cap. 2, los componentes de la atmósfera producen un efecto de absorción y dispersión, que modifican, a veces notablemente, la señal procedente de la cubierta. Además, este efecto es dependiente de la longitud de onda —afectando especialmente a las más cortas—, por lo que no puede prescindirse de él, ni siquiera para realizar transformaciones entre bandas. También dependiente de la atmósfera el denominado efecto de adyacencia, que implica que se reciba energía procedente de cubiertas vecinas. Este efecto reduce el contraste de la escena y puede dificultar la discriminación entre objetos vecinos (Itten y Meyer, 1993). Por otra parte, la observación vertical puede asumirse para buena parte de los sensores de interés ambiental (Landsat-MSS, TM, ETM+, IRS-LISS...), pero no siempre para

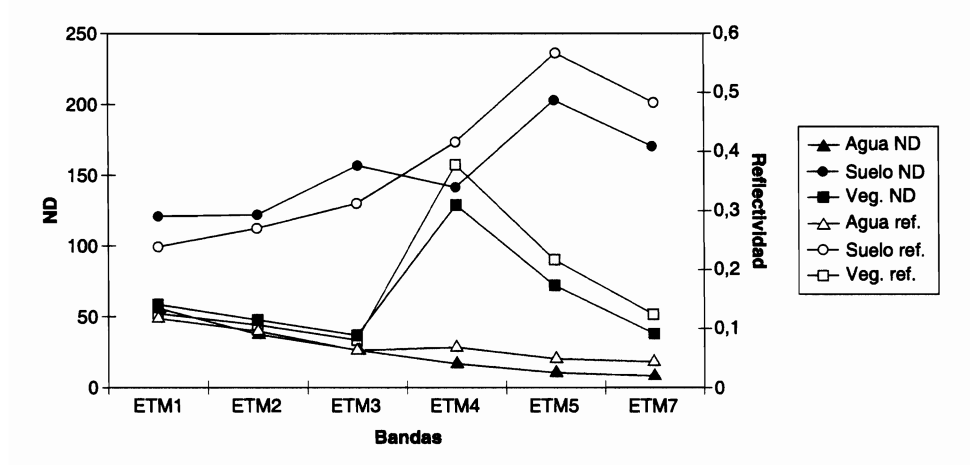


FIG. 6.28. *Comparación entre las curvas espectrales de los ND brutos y con reflectividad aparente para el agua, suelo descubierto y vegetación.*

otros que poseen la capacidad de observar áreas oblicuamente, de cara a mejorar su cobertura temporal o plantear modelos estereoscópicos, como ocurre con el SPOT-HRV o el IKONOS, o con el NOAA-AVHRR, con un ángulo muy amplio de barrido. En tercer lugar, el terreno plano sólo es asumible cuando las pendientes sean realmente bajas (< 5º) y no existan variaciones de iluminación por efecto de la vertiente. Finalmente, el carácter lambertiano de las cubiertas es tanto menos nítido cuanto menos rugosas sean.

En los siguientes epígrafes comentaremos el efecto de estos factores sobre la señal recibida por el sensor y plantearemos algunos métodos prácticos para abordar su corrección. Dividiremos este comentario en tres grandes factores: la atmósfera, el efecto del relieve y el carácter direccional de la reflectividad.

6.2.3.2. Correcciones atmosféricas



La influencia atmosférica no afecta por igual a los dos componentes del cálculo de la reflectividad: flujo descendente (denominador) y ascendente (numerador), ya que el espesor de la atmósfera que atraviesan es distinto. Además, hay que considerar que a la irradiancia solar directa (la medida en las tablas) hay que añadir la difusa, procedente de otros objetos vecinos (E_d en la fig. 6.29). En definitiva, la radiancia que recibe el satélite no es la misma que sale del suelo. Ésta es la que interesa, pues pretendemos medir la reflectividad de la cubierta, no la influida por la atmósfera, sino que es fruto de los siguientes parámetros (Gilabert *et al.*, 1994):

$$L_{sen,k} = L_{su,k}\, \tau_{k,o} + L_{a,k} \tag{6.26}$$

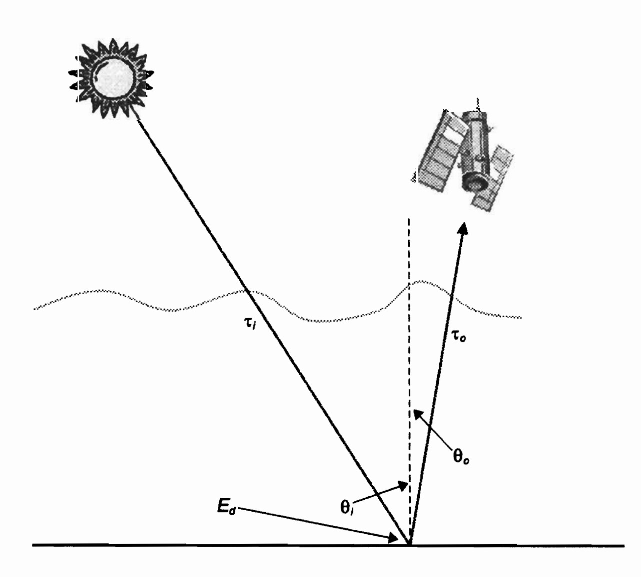


FIG. 6.29. *Efectos atmosféricos sobre el cálculo de la reflectividad.*

donde $L_{su,\,k}$ es la radiancia que sale de la superficie; $\tau_{k,\,o}$, la trasmisividad de la atmósfera para el flujo ascendente, y $L_{a,\,k}$ la radiancia aportada por la dispersión atmosférica. La transmisividad en la dirección ascendente depende del espesor óptico de ozono ($\tau_{oz,\,k}$), de aerosoles ($\theta_{a,\,k}$), y del espesor óptico molecular ($\tau_{r,\,k}$) para esa misma banda, y del ángulo de observación (θ_o):

$$\tau_{k,o} = \exp((-\tau_{oz,k} - \tau_{a,k} - \tau_{r,k}) / \cos\theta_o) \qquad \{6.27\}$$

El ángulo de observación sólo debe considerarse cuando la adquisición no es vertical, como ocurre en algunas tomas del SPOT o IKONOS, o para ángulos de abertura muy amplios, caso del AVHRR.

Respecto al flujo incidente, tampoco resulta fidedigno el parámetro indicado en {6.25}, ya que la irradiancia que llega al suelo ($E_{su,\,k}$) no es la que medimos en el techo de la atmósfera ($E_{0,\,k}$), sino que también está afectada por la atmósfera y por el componente de luz difusa:

$$E_{su,k} = E_{o,k} \cos\theta_i \, \tau_{k,i} + E_{d,k} \qquad \{6.28\}$$

donde $E_{0,\,k}$ y $\cos\theta_i$ tienen el mismo significado de {6.25}; $\tau_{k,\,i}$ es la transmisividad atmosférica que afecta al rayo incidente, y $E_{d,\,k}$ es la irradiancia difusa, como consecuencia de la dispersión Rayleigh y Mie, que también depende de las condiciones de la atmósfera.

La transmisividad del rayo incidente tiene una expresión similar a la que afecta al flujo reflejado, cambiando el ángulo de observación por el de incidencia (θ_i):

$$\tau_{k,i} = \exp((-\tau_{oz,k} - \tau_{a,k} - \tau_{r,k}) / \cos\theta_i) \qquad \{6.29\}$$

En suma, para conocer la reflectividad real de la cubierta en una determinada banda k (ρ_k), definida por:

$$\rho_k = \frac{D\pi L_{su,k}}{E_{su,k}} \qquad \{6.30\}$$

es preciso resolver la siguiente fórmula (a partir de {6.26} y {6.28}):

$$\rho_k = \frac{D\pi((L_{\text{sen},k} - L_{a,k}) / \tau_{k,o})}{E_{o,k} \cos\theta_i \, \tau_{k,i} + E_{d,k}} \qquad \{6.31\}$$

En definitiva, para calcular la reflectividad de la superficie necesitamos remover los efectos atmosféricos, que suponen estimar la transmisividad de la atmósfera (descendente, $\tau_{k,\,i}$, y ascendente, $\tau_{k,\,o}$), la irradiancia difusa ($E_{d,\,k}$) y la radiancia atmosférica debida a la dispersión ($L_{a,\,k}$).

Los procedimientos para abordar estas correcciones con precisión son muy laboriosos y requieren datos sobre las condiciones de la atmósfera en el momento de

tomar la imagen, que no suelen estar disponibles. Además, el efecto de la atmósfera no es constante en la imagen, sino que determinadas zonas pueden haber sido más afectadas que otras, en función de la diversa presencia de aerosoles o vapor de agua.

Hasta el momento, las correcciones atmosféricas se han abordado siguiendo cuatro procedimientos (King *et al.*, 1999; Robin, 1998; Sobrino, 2000):

1. A partir de medidas *in situ*, ya sean referidas a perfiles de la composición atmosférica mediante radiosondeos, ya a estimaciones cualitativas del espesor óptico (midiendo, por ejemplo, la visibilidad), o mediante mediciones en terreno de la radiancia solar incidente o de la reflectividad en el terreno. Estos métodos resultan, en general, los más precisos, por cuanto facilitan una medición de las condiciones atmosféricas durante la toma de la imagen, pero rara vez están disponibles.
2. A partir de imágenes de otros sensores, que permitan estimar el estado de la atmósfera en el momento de adquisición de las imágenes. Pese a la gran lógica de este planteamiento: dos sensores, uno mide los objetos de interés, y otro mide la atmósfera cuando se toman los datos, este enfoque resulta bastante novedoso ya que sólo muy recientemente se han diseñado misiones con esta concepción. Por ejemplo, la plataforma Terra, como ya hemos visto, incluye el sensor MISR que mide simultáneamente con varios ángulos, lo que permite estimar el espesor atmosférico, y facilitar las correcciones atmosféricas de los otros sensores a bordo (como el MODIS). Si bien la resolución espacial de esos sensores no es la misma, la integración entre estos datos resulta muy beneficiosa para obtener productos calibrados de adecuada precisión (King *et al.*, 1999). No obstante, todavía hay pocas experiencias prácticas de este planteamiento.
3. A partir de modelos físicos de transferencia radiativa, que suelen basarse en una serie de atmósferas estándar. La precisión de los modelos dependerá, como es lógico, de la solidez de las asunciones que se realicen y de la similitud entre los perfiles teóricos y las condiciones concretas de la atmósfera cuando se toma la imagen.
4. A partir de datos de la propia imagen. Este sería, sin duda, el método más operativo, pues no requeriría información externa y facilitaría una corrección completa de los datos.

De las cuatro posibles soluciones al problema de la corrección atmosférica nos vamos a centrar en este epígrafe en las dos últimas, pues resultan, por el momento, las más accesibles. En lo que se refiere al empleo de modelos de transferencia radiativa con atmósferas estándar, existen ya algunos programas bastante operativos, que realizan la estimación del efecto atmosférico con bastante precisión, siempre y cuando se dé una buena similitud entre las condiciones atmosféricas de la imagen y las estándar incluidas en el modelo. Sin duda, los modelos más conocidos son el 6S (Vermote *et al.*, 1997) y el MODTRAN4 (Berk *et al.*, 1999). Ambos cuentan ya con numerosas versiones (aquí se han citado las últimas) que van enriqueciendo las asunciones que inicialmente se plantearon en su diseño. El 6S (segunda simulación de la señal de satélite en el espectro solar) fue desarrollado inicialmente por el laboratorio de óptica atmosférica de la Universidad de Lille. En la última versión simula observaciones planas, considera la elevación, permite tener en cuenta el carácter no lambertiano de la superficie, e incluye nuevos gases (CH_4, N_2, O, CO) en el cál-

FIG. 6.30. *Parámetros para la corrección atmosférica sobre modelos de transferencia radiativa (ATCOR).*

culo de la transmisión gaseosa. Facilita una estimación del efecto atmosférico para todo el espectro óptico, con bandas de hasta 0,025 µm de anchura. Por su parte, el MODTRAN4 es una nueva versión de un modelo desarrollado por la fuerza aérea norteamericana junto a una empresa privada *(Spectral Sciences, Inc)*. También considera los efectos de reflectividad bidireccional (BRDF) en terreno y de reflectividad de objetos cercanos (adyacencia).

Desde el punto de vista de su clara operatividad también conviene destacar el modelo ATCOR4, desarrollado por Richter (1996; 1997), incluido en varios programas de ADI (*PCI-Geomatics.*), así como el ACORN y FLAASH [Kruse, 2004 #5086]. El modelo ATCOR basa la corrección en una serie de perfiles atmosféricos estándar, que se incluyen con el programa, aunque son fácilmente adaptables por el usuario en caso de que se cuente con información más detallada. Estas definiciones incluyen el contenido de vapor de agua y el tipo de aerosoles. El programa requiere únicamente una estimación del espesor atmosférico, indicando un rango de visibilidad (en km), y una altura promedio de la zona (si bien también puede incorporarse un MDT). Incluye los coeficientes de calibración estándar para el SPOT-HRV y el Landsat-TM, pero el usuario puede incluir fácilmente los correspondientes a otros senso-

res. También se precisa introducir el ángulo cenital solar. El programa incluye opcionalmente una estimación del efecto de adyacencia, que es causada por la dispersión procedente de cubiertas vecinas, a partir de considerar las diferencias entre la reflectividad del píxel y la correspondiente a los alrededores (en este caso, se considera un área de 1 × 1 km). El autor del modelo advierte que este modelo sólo funciona adecuadamente para sensores de observación cuasi vertical (se acepta una tolerancia de ±8º), en zonas por debajo de 1.500 m de altitud y con pendientes moderadas.

Naturalmente, lo ideal sería poder derivar la corrección atmosférica de los datos de la propia imagen, si consiguiéramos encontrar alguna función que extrajera de la señal detectada por el sensor la parte correspondiente a las condiciones atmosféricas. Las alternativas para llevar a cabo esta tarea se pueden resumir en cuatro posibilidades: estimar la contribución de la atmósfera a partir de cubiertas que deberían presentar una reflectividad nula (métodos basados en el «objeto oscuro»); estimar el efecto atmosférico a partir de las diferencias de absorción y dispersión en distintas bandas del espectro para la misma imagen; realizar una homogeneización multitemporal entre imágenes y observar la misma zona con distintos ángulos. Esta última vía, que ya hemos comentado en anteriores capítulos, sólo ha estado disponible en los últimos años, gracias a disponer de sensores con capacidad multiangular. El análisis multitemporal lo trataremos más adelante (7.3). La estimación de las condiciones de la atmósfera a partir de la observación multibanda se ha desarrollado ampliamente en la corrección de imágenes térmicas, como luego comentaremos (6.6.2.4). En consecuencia, nos detendremos aquí únicamente en la primera opción, que resulta una de las más sencillas.

La propuesta inicial de los métodos basados en el objeto oscuro *(dark object)* fue realizada por Chavez en 1975, con sucesivas mejoras en 1988 y 1996 (Chavez, 1975; Chavez, 1996; Chavez, 1988). El punto de partida del método consiste en asumir que las áreas cubiertas con materiales de fuerte absortividad (agua, zonas en sombra), deberían presentar una radiancia espectral muy próxima a cero. En la práctica, el histograma de los ND de la imagen siempre presenta un mínimo superior a ese valor, que se atribuye al efecto de dispersión atmosférica. Asimismo, se observa que ese valor mínimo es mayor en las bandas más cortas, disminuyendo hacia el IRC y SWIR. Como ya vimos, la dispersión Rayleigh —la más común— afecta principalmente a las longitudes de onda más cortas, lo que confirma que ese valor mínimo puede corresponder más al efecto de la atmósfera que a la radiancia espectral proveniente de la superficie terrestre. En suma, una sencilla aproximación a la corrección atmosférica consiste en asumir que la radiancia atmosférica ($L_{a,k}$) corresponde al valor mínimo del histograma. La asunción puede ser bastante correcta siempre que tengamos en la imagen zonas en sombra o con agua profunda. Incluso se puede plantear establecer una red de superficies oscuras en la imagen y realizar luego una interpolación para tener mejor en cuenta la variedad espacial del espesor atmosférico (Ouaidrari y Vermote, 1999).

El método del objeto oscuro resulta muy sencillo, y es válido para estimar el espesor atmosférico de aerosoles, pero los errores pueden ser notables para valores de reflectividad altos (por encima del 15 %), al no considerar las transmisividades del flujo incidente y reflejado. Para evitar este problema, se ha sugerido complementarlo con estimaciones en el terreno de la transmisividad o con parámetros climáti-

cos auxiliares (principalmente para estimar el contenido de vapor de agua y de ozono: (Ouaidrari y Vermote, 1999). La última versión de la propuesta de Chavez sugiere estimar la transmisividad a partir del espesor atmosférico, que sugiere definirlo por el coseno del ángulo cenital (θ_i) (Chavez, 1996). Además, el autor sugiere no considerar la irradiancia difusa. En pocas palabras, para observaciones verticales, la fórmula {6.31} quedaría como:

$$\rho_k = \frac{D\pi(L_{sen,k} - L_{a,k})}{E_{o,k} \cos\theta_i^2} \qquad \{6.32\}$$

donde $L_{a,k}$ se estimaría a partir del valor mínimo o de un objeto de reflectividad nula ($L_{a,k} = a_{0,k} + a_{1,k}\, ND_{min}$). El autor asume que la transmisividad ascendente es 1, lo cual parece razonable para observaciones verticales.

Sin embargo, se ha observado que la transmisividad atmosférica aumenta con la longitud de onda, por lo que de acuerdo al modelo de Chavez, en principio se corrige poco la banda TM1 y mucho la banda TM4. La transmisividad se hace prácticamente 1 para TM5 y 7 (Gilabert *et al.*, 1994), con lo que en estas bandas la corrección del coseno no sería aplicable porque dichas bandas quedarían demasiado corregidas. En consecuencia, como alternativa a la corrección del coseno, sugiere emplear unos valores de transmisividad estándar. La fórmula propuesta, en este caso, quedaría finalmente como:

$$\rho_k = \frac{D\pi(L_{sen,k} - L_{a,k})}{E_{o,k} \cos\theta_i \tau_{k,i}} \qquad \{6.33\}$$

donde $t_{k,i}$ = 0,70 (TM1), 0,78 (TM2), 0,85 (TM3), 0,91 (TM4) y 1 para las bandas del SWIR (TM5 y 7). Estos valores de $t_{k,i}$ son muy similares a los propuestos por otros autores. Gilabert et al. (1994) sugieren, respectivamente, 0,73; 0,79; 0,85; 0,91; 0,95 y 0,97 para las mismas longitudes de onda. Pons y Solé (1994) también proponen unos valores promedio, similares a los anteriores, aunque se matizan en función del ángulo cenital solar.

En la figura 6.31 se incluye una comparación gráfica entre las reflectividades calculadas por el método de Chavez (con transmisividades promedio) y las que obtuvimos en el epígrafe anterior (reflectividad aparente). El efecto de la corrección resulta bastante obvio, sobre todo en lo que se refiere a la banda azul, en donde los valores decrecen notablemente. Además, se observa el comportamiento típico de la vegetación con las bandas de absorción en el azul y rojo, que quedaban muy distorsionadas por el efecto atmosférico en la reflectividad aparente. También el agua presenta una curva de reflectividad más similar a lo esperable, con valores bajos y descendentes hacia longitudes más largas, si bien aquí puede haberse producido una sobre-corrección de la banda azul. En la siguiente figura (6.32), se comparan los métodos de Chavez y Richter (ATCOR) para las mismas cubiertas que hemos visto en anteriores gráficos. Como puede observarse, el efecto de la corrección es bastante comparable entre métodos, especialmente en agua y vegetación. No obstante, se observa que el método de

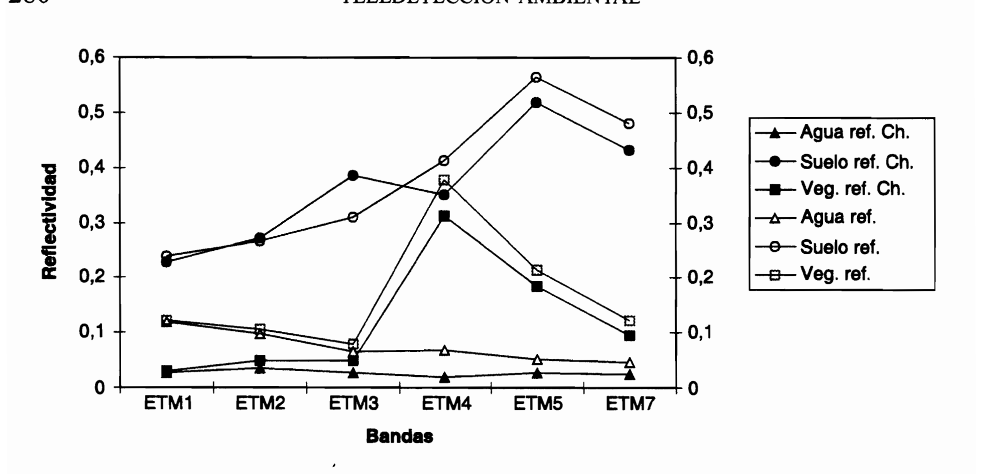


FIG. 6.31. *Comparación entre las curvas de reflectividad aparente y las corregidas atmosféricamente por el método de Chavez.*

Chavez infraestima la transmisividad en la banda roja, como se muestra en que la vegetación no ofrezca una banda de absorción en relación con el verde, y el trazado anómalo de la curva del suelo. Ambas parecen sobre-estimar el efecto atmosférico en la banda azul. La comparación entre ellas requeriría un análisis más detallado, aplicado a imágenes de distintas fechas. Se aplicaron estos dos métodos a dos imágenes Landsat-TM sobre imágenes de verano en el Centro de la Península, observándose que el ATCOR sobre-estimaba la corrección en las bandas cortas (ofreciendo incluso valores negativos), frente a una infra-estimación en el NIR y SWIR (Riaño *et al.*, 2003).

6.2.3.3. Correcciones del sombreado topográfico

Otro elemento importante que conviene considerar en el cálculo de reflectividades es el efecto del relieve. La reflectividad es muy dependiente de los ángulos de

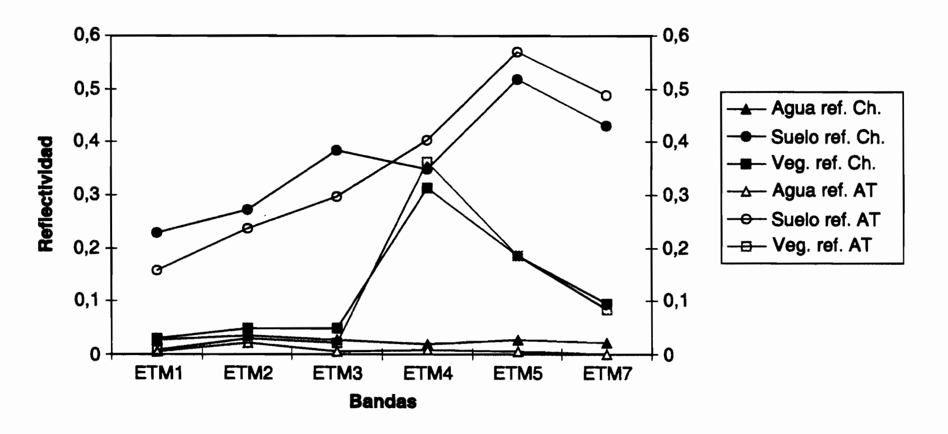


FIG. 6.32. *Comparación entre las curvas de reflectividad obtenidas por el método de Chavez y por el ATCOR.*

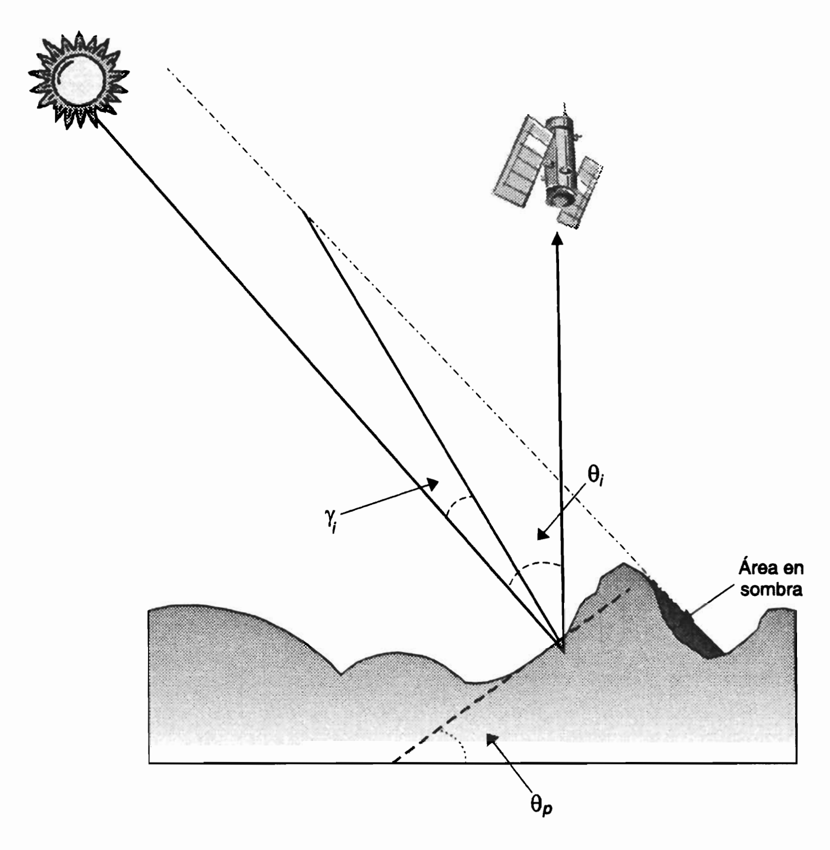


FIG. 6.33. *Efecto del relieve sobre la radiancia detectada por el sensor.*

incidencia y observación. Hemos asumido hasta aquí que el ángulo de la radiación incidente sólo depende de la elevación solar, lo que implica asumir que el terreno es llano. Dicha consideración, como es lógico, sólo será válida si realmente se trata de una superficie de escasa pendiente, siendo arriesgada cuando no sea así. Los efectos derivados del gradiente y dirección de la pendiente son bastante notorios, especialmente en las zonas en sombra. La creciente disponibilidad de modelos digitales de elevación (MDE), permite abordar con ciertas garantías esta corrección, homogeneizando la señal de la misma cubierta independientemente de la vertiente en que se encuentre.

Repasando la figura 6.28 podemos observar cómo la energía incidente está en función del ángulo cenital solar (θ_i). La máxima energía, para una determinada banda se obtiene cuando el ángulo cenital es de 0 grados ($\cos \theta_i = 1$), esto es cuando el sol incide verticalmente. El ángulo cenital, como ya indicamos, se calcula como el complementario del ángulo de elevación solar, que suele recogerse en la cabecera de la imagen. Ahora bien, en un terreno montañoso la pendiente modifica la geometría del flujo incidente (fig. 6.33). Por un lado, en las laderas orientadas al sol el ángulo cenital no coincide con el ángulo de incidencia, mientras en las opuestas puede ocurrir que no se reciba en absoluto energía solar directa, cuando la vertiente está

en umbría. Si no se tiene en cuenta este efecto del relieve, la reflectividad medida para la misma cubierta en distintas vertientes puede ser muy variada, implicando severos problemas en el reconocimiento y clasificación de coberturas temáticas.

Una manera muy sencilla de eliminar el efecto topográfico sería realizar un simple cociente entre dos bandas de la misma imagen. Puesto que los ángulos de incidencia son constantes entre bandas (el cos θ_i en la fórmula {6.22}), cuando se realiza un cociente entre bandas adquiridas simultáneamente, este efecto se elimina. Por ejemplo, utilizando las reflectividades aparentes:

$$Coc_{k,m} = \frac{\rho^*_k}{\rho^*_m} = \frac{\dfrac{D\pi L_{sen,k}}{E_{0,k}\cos\theta_i}}{\dfrac{D\pi L_{sen,m}}{E_{0,m}\cos\theta_i}} = \frac{\dfrac{L_{sen,k}}{E_{0,k}}}{\dfrac{L_{sen,m}}{E_{0,m}}} \qquad \{6.34\}$$

Esto es una forma simplificada de eliminar los efectos topográficos, ya que la radiancia y la transmisividad atmosférica, y la irradiancia difusa no son las mismas entre bandas. Los efectos atmosféricos no son independientes de la longitud de onda, pero ciertamente se reduce el factor del relieve, como luego tendremos ocasión de ver en los índices espectrales de vegetación (cap. 7.1).

Caso de que pueda disponerse de un MDE de similar resolución espacial que la imagen y bien ajustado a la imagen, se puede estimar la variación introducida en la reflectividad por el efecto topográfico a partir de modelar las condiciones de iluminación en el momento de adquirirse la imagen. Para ello, necesitamos en primer lugar calcular el ángulo de incidencia (γ_i) de una vertiente, que depende de los ángulos solares y de pendiente (Civco, 1989; Colby, 1991; Conese *et al.*, 1993):

$$\cos\gamma_i = \cos\theta_i \cos\theta_p + \text{sen}\theta_i \text{sen}\theta_p \cos(\phi_a - \phi_o) \qquad \{6.35\}$$

donde γ_i corresponde al ángulo de incidencia, θ_i indica el ángulo cenital solar, θ_p el gradiente de la pendiente, ϕ_a el ángulo acimutal solar y ϕ_o el ángulo de orientación de la pendiente. Estos cuatro ángulos pueden obtenerse del MDE y de la fecha y hora de adquisición de la imagen. El cos γ_i nos sirve para valorar el efecto de iluminación en la vertiente y es equivalente al sombreado que recogen numerosos programas SIG. Como es lógico, varía entre –1 y +1, indicando para cada píxel del MDE las condiciones de mínima y máxima iluminación, respectivamente. La figura 6.34 recoge un fragmento de la imagen Torre100, en su sector más montañoso, junto con la imagen de iluminación (cos γ_i) para la misma zona y condiciones de adquisición de la imagen. Las flechas indican en qué sectores resulta especialmente evidente el efecto del sombreado sobre la imagen original.

A partir de haber calculado el ángulo de incidencia, pueden plantearse distintos métodos para compensar la diferencia de radiación incidente entre vertientes. Entre los propuestos cabe distinguir los que consideran las cubiertas como lambertianas, y las que tienen en cuenta efectos direccionales (Itten y Meyer, 1993; Riaño *et al.*, 2003). Entre los primeros el más sencillo es el propuesto por Teillet (1982):

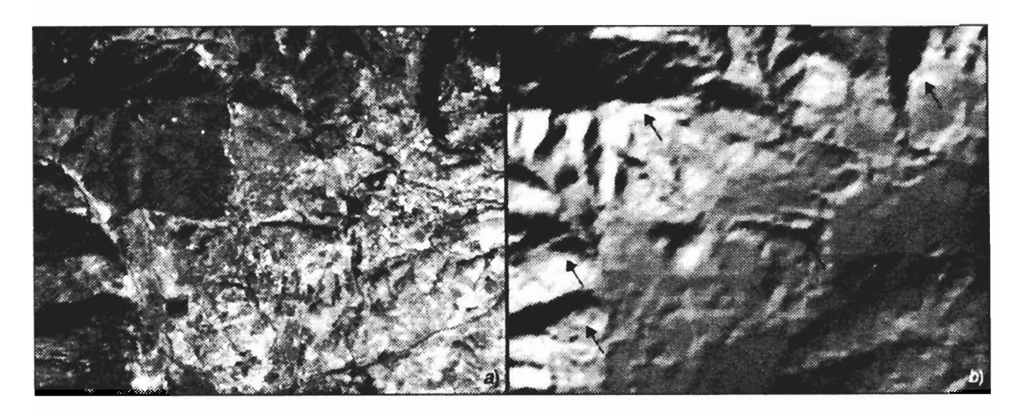


FIG. 6.34. *Ventana de la imagen Torre100 sobre un sector montañoso: (a) banda 4 original, (b) sombreado derivado del MDE.*

$$\rho_{h,i} = \rho_i \left(\frac{\cos\theta_i}{\cos\gamma_i} \right) \qquad \{6.36\}$$

donde $\rho_{h,i}$ indica la reflectividad de un píxel i en terreno horizontal, ρ_i la misma en pendiente (la correspondiente a la imagen), θ_i el ángulo cenital solar de la escena y γ_i el ángulo de incidencia correspondiente a ese píxel. Este método se ha demostrado que sobre-corrige la imagen, sobre todo en las zonas de muy baja iluminación (Duguay y LeDrew, 1992; Holben y Justice, 1981; Meyer *et al.*, 1993), por lo que se ha propuesto posteriormente ponderar la imagen de iluminación en función de las condiciones promedio de iluminación de la imagen (Civco, 1989):

$$\rho_{h,i} = \rho_i + \rho_i \frac{(\cos\gamma_m - \cos\gamma_i)}{(\cos\gamma_m)} \qquad \{6.37\}$$

donde el subíndice m indicaría el valor promedio de la iluminación en la imagen de interés.

Este modelo reduce el efecto topográfico, aunque no todo lo que debiera. Tanto en esta corrección como en la anterior se sigue suponiendo que el efecto topográfico es constante para todas las bandas.

Entre los métodos no lambertianos uno de los más citados es el propuesto por Minnaert para evaluar la rugosidad de la superficie lunar (Minnaert, 1941):

$$\rho_{h,i} = \rho_i \left(\frac{\cos\theta_i}{\cos\gamma_i} \right)^l \qquad \{6.38\}$$

donde el parámetro l se introduce para modelar el comportamiento no lambertiano de los cuerpos. Si l = 1, la superficie se comporta como un reflector lambertiano

ideal. El problema de este método es conseguir un cálculo certero de l, ya que varía en cada banda y cada superficie. Una manera sencilla de tener en cuenta, al menos, la importancia del carácter lambertiano en cada banda es realizar un ajuste semi-empírico como el propuesto en la corrección C (Teillet *et al.*, 1982):

$$\rho_{h,i} = \rho_i \left(\frac{\cos\theta_i + c_k}{\cos\gamma_i + c_k} \right) \qquad \{6.39\}$$

donde c_k es una constante empírica para cada banda k que se relaciona con la rugosidad promedio de esa banda, y se obtiene a partir de:

$$c_k = \left(\frac{b_k}{m_k} \right) \qquad \{6.40\}$$

siendo b_k y m_k la constante y la pendiente, respectivamente, de la recta de regresión entre la imagen de reflectividad de la banda k y la imagen de iluminación. Este método dio buenos resultados para cartografía de la cubierta vegetal, no observándose sesgos ni valores anómalos significativos (Riaño *et al.*, 2002).

El problema de estas correcciones sencillas es la falta de consideración de la irradiancia difusa, que puede ser importante en las vertientes situadas a umbría. Se han propuesto algunas alternativas para resolver ese problema, pero resultan más complicadas en su aplicación práctica. Por ejemplo, Conese *et al.* (1993) proponen utilizar una variación de la fórmula para la radiancia incidente que considere los efectos de la pendiente:

$$E^*_{su,k} = E_{0,k} \cos\cos\gamma_i \, \tau_{k,i} + E^*_{d,k} \qquad \{6.41\}$$

donde $E^*_{su,k}$ y $E^*_{d,k}$ indican la radiancia que llega al suelo y la difusa, respectivamente, en un terreno montañoso. Si el ángulo de incidencia (γ_i) supera los 90° (o, si se prefiere, el cos $\gamma < 0$), la vertiente está en sombra. No hay, por tanto, iluminación directa, y la que llega al suelo es únicamente la difusa ($E^*_{d,k}$), que se calcula a partir de las condiciones atmosféricas en función del ángulo de incidencia, de la pendiente del terreno y de un coeficiente de anisotropía ($E_{su,k}/E_{o,k}$), dependiente de la banda y la fecha de observación. Para el ámbito de trabajo presentado por estos autores, esta corrección topográfica mejora bastante el cálculo de reflectividades en zonas de topografía quebrada, reduciendo notablemente la variabilidad espectral de los tipos de cubierta. No obstante, los autores advierten que el algoritmo resulta poco adecuado para imágenes de invierno o topografía muy abrupta, con ángulos de incidencia muy bajos (Conese *et al.*, 1993). Esta misma conclusión se manifiesta por otros autores que han propuesto métodos más o menos similares para el cálculo de la irradiancia difusa (Itten y Meyer, 1993; Richter, 1997).

Un ejemplo del efecto de las correcciones topográficas sobre nuestra zona de estudio se presenta en la figura 6.35, que incluye la misma zona de la figura anterior. En este caso se compara la banda 4 antes y después de aplicarle la corrección de ilu-

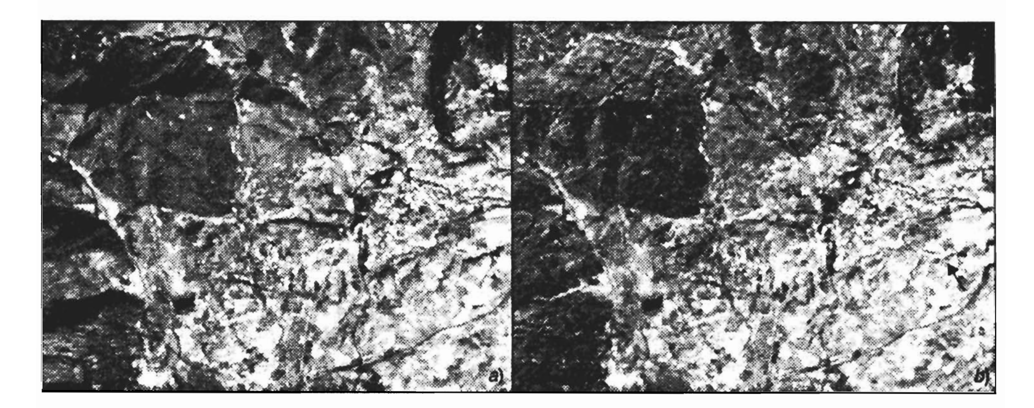


FIG. 6.35. *Efecto de la corrección del sombreado sobre el sector de la figura anterior: (a) banda 4 original; (b) banda 4 corregida.*

minación, utilizando el método de Civco que, para esta fecha, da buenos resultados. Las flechas indican los sectores donde el efecto de corrección resulta más evidente. Una manera de verificar el efecto de la corrección es calcular la correlación entre la imagen de iluminación y las bandas de la imagen, antes y después de corregir. Para nuestra zona de estudio, la correlación disminuye tras la corrección de 0,18 a 0,13 en la banda 4 y de 0,25 a 0,14 en la 5, indicando que se ha eliminado parte del efecto topográfico sobre la señal. Otra verificación nos llevaría a medir las diferencias de reflectividad en una serie de cubiertas situadas a distintas vertientes. Si la corrección es certera deberían homogeneizarse los valores, eliminando sus diferencias debidas a la insolación. Esta hipótesis se comprobó por Riaño (2003) en su estudio sobre cartografía de combustibles forestales en el Parque Nacional de Cabañeros (Riaño *et al.*, 2002). Las correcciones topográficas redujeron la desviación típica de la mayor parte de las especies vegetales, con especial intensidad en las bandas TM 4 y 5. La figura 6.36 nos muestra el efecto de la corrección del sombreado topográfico sobre esta zona, empleando imágenes TM adquiridas en julio de 1997. De nuevo, las flechas nos indican los sectores más claramente modificados por la corrección.

6.2.3.4. Corrección del efecto bidireccional (BRDF)

El último aspecto que vamos a considerar en el cálculo de la reflectividad hace referencia al efecto que los ángulos de observación y de iluminación tienen sobre la reflectividad detectada por el sensor. Como ya hemos comentado a lo largo de las páginas precedentes es frecuente asumir en los modelos para el cálculo de reflectividad que una cubierta presenta un comportamiento lambertiano, lo que implica considerar que la radiancia reflejada por esa cubierta sea igual en todas las direcciones. Esta asunción es razonable como primera aproximación al cálculo de la reflectividad, pero dista bastante de ser correcta. Todos tenemos la experiencia directa de cómo cambia la visión de un objeto según se sitúe el observador en relación con la luz incidente (fig. 6.37), por lo que parece razonable tener en cuenta este factor en los cálculos más detallados de la reflectividad.



FIG. 6.36. *Fragmento de la imagen Cabañeros97 antes (a) y después (b) de aplicarle la corrección de iluminación. Con flechas se indican los sectores más afectados. (Cortesía David Riaño.)*

Hasta hace relativamente poco la mayor parte de los sensores ofrecían únicamente visión vertical, por lo que se asumía que la señal que medían eran comparable en el tiempo, lógicamente con las variaciones atmosféricas y de iluminación pertinentes. Sin embargo, en el caso de otros sensores de ángulos más amplios de barrido, como los meteorológicos, las zonas observadas podían variar no sólo por estos factores, sino también por la variación en las condiciones de iluminación y de observación. En otras palabras, cuando las observaciones no se realizan con los mis-

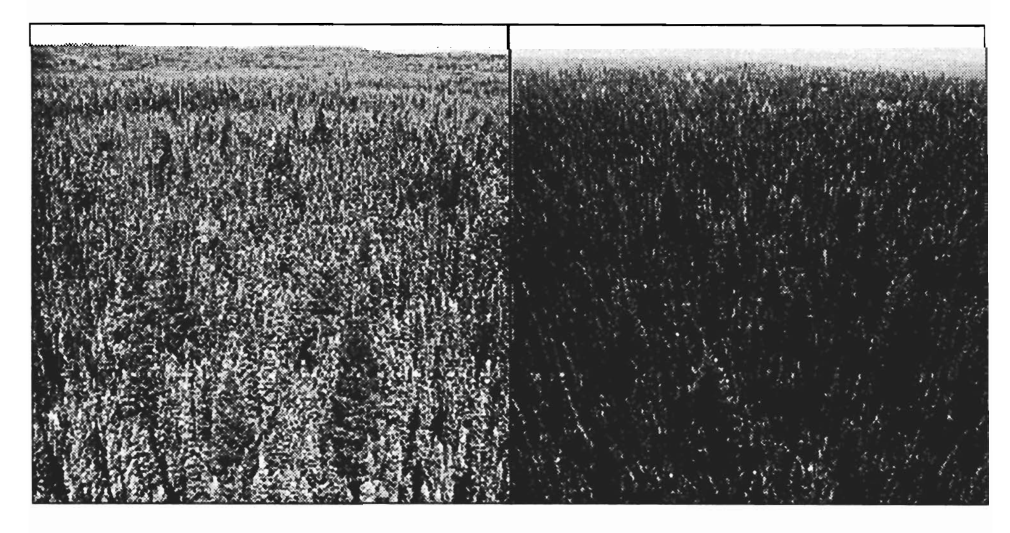


FIG. 6.37. *Variaciones en la reflectividad de una cubierta forestal por efecto de los ángulos de observación. En la foto de la izda., el sol está detrás de la cámara; en la dcha. delante. (Tomado de http://crsa.bu.edu/~nstrug/brdf/BRDF Explained.htm)*

mos ángulos (solares y del sensor), no son perfectamente comparables, por lo que las series temporales pueden ser bastante inconsistentes. En el caso del AVHRR, uno de los sensores más utilizados en análisis temporal de la vegetación, este factor tendía a paliarse mediante métodos que eligieran, dentro de una serie de imágenes diarias, aquellos píxeles más cercanos a una visión vertical, pero esto no siempre se garantiza por el problema de la cobertura de nubes. En consecuencia, si quieren utilizarse las series diarias es preciso introducir algún tipo de corrección del efecto direccional.

Para abordar estas correcciones se utilizan las llamadas funciones de distribución de reflectividad bidireccional (BRDF, *Bidirectional Reflectance Distribution Factor*). Se trata éste de un concepto teórico, que describe los efectos direccionales de la reflectividad comparando la radiancia reflejada en una determinada dirección con la incidente en otra (Sandmeier y Itten, 1999):

$$f(\theta_i, \phi_i; \theta_r, \phi_r, \lambda) = \frac{dL(\theta_r, \phi_r, \lambda)}{dE(\theta_i, \phi_i, \lambda)} \qquad \{6.42\}$$

donde dL es la radiancia reflejada con un determinado ángulo cenital (θ_r) y acimutal (ϕ_r) y dE la irradiancia incidente con una determinada dirección: cenital (θ_i) y acimutal (ϕ_i) (fig. 6.38). Le hemos añadido el parámetro λ para indicar que la BRDF es también dependiente de la longitud de onda, o, lo que es lo mismo, que las diferencias debidas a las direcciones de observación no van a afectar por igual a las distintas bandas del espectro, siendo más severos los efectos direccionales en las longitudes más cortas (principalmente en el azul y rojo para el caso de la vegetación: (Sandmeier y Itten, 1999). A veces puede resultar más gráfico que la función BRDF el denominado factor de anisotropía, que relaciona la reflectividad de una cubierta en una dirección determinada con la que se obtendría para una dirección de referencia, normalmente, para una observación vertical:

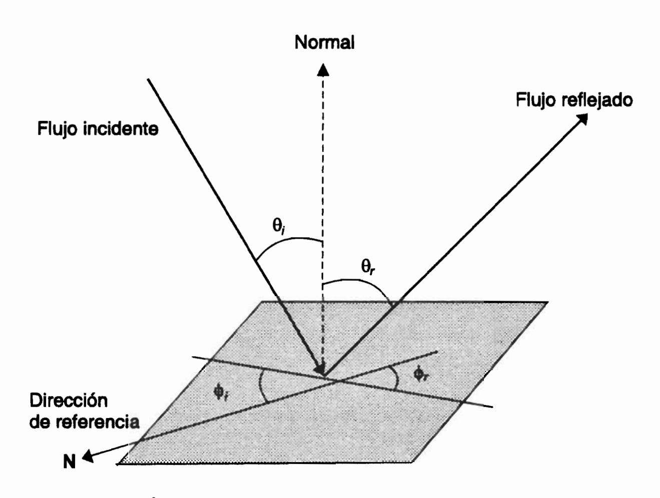


FIG. 6.38. *Ángulos que intervienen en el cálculo de la BRDF.*

$$\mathrm{ANIF}(\theta_i, \phi_i; \theta_r, \phi_r, \lambda) = \frac{R(\theta_r, \phi_r, \lambda)}{R_o(\theta_r, \phi_r, \lambda)} \qquad \{6.43\}$$

Estos factores son de gran interés para conocer mejor el comportamiento direccional de una determinada cubierta. Nos permitirían estandarizar las reflectividades observadas a una base común, siempre que conozcamos los ángulos solares y de situación del sensor. Algunos ejemplos de estos gráficos se incluyen en la fig. 6.39 para el caso concreto de una cubierta herbácea. Se observa que la misma cubierta presenta efectos direccionales muy distintos según la longitud de onda. En las bandas de fuerte absorción (azul y rojo), esta cubierta tiende a ofrecer un claro componente direccional, con mayores intensidades hacia ángulos próximos a la vertical y cuando se observa de espaldas al sol. Por su parte, el IRC y, en menor medida, el verde tienen un efecto direccional menos marcado.

Para poder introducir estas correcciones en las imágenes necesitamos información sobre el carácter iso o anisotrópico de las cubiertas que observamos, en definitiva contar con sus BRDF. Esta información no es fácilmente accesible, ya que hasta hace relativamente poco no se contaba con sensores de observación multiangular. La mayor parte de los estudios disponibles se basan en goniómetros de campo (Sandmeier y Itten, 1999), si bien se están construyendo actualmente estas funciones a partir de algunos sensores más modernos (como el MISR o el POLDER). Conocer el BRDF de una cubierta no sólo servirá para mejorar su discriminación, eliminando la parte de la señal que proceda de los ángulos de observación, sino que en sí mismo será una variable más que permita introducir discriminaciones más sutiles, por ejemplo, debidas a efectos de sombra en determinadas especies forestales. De ahí el interés por enriquecer la signatura espectral de una determinada cubierta añadiendo también lo que podríamos llamar su «signatura angular», o mejor aún las variaciones angulares de las signaturas espectrales. Este enfoque se ha desarrollado hasta el momento con sensores aeroportados (Sandmeier y Deering, 1999).

A efectos prácticos es difícil introducir este parámetro en los cálculos de reflectividad, ya que la BRDF depende del tipo de cubierta que estemos observando, la cual será habitualmente desconocida en una primera interpretación. Para el caso de las imágenes AVHRR, se ha propuesto una corrección relativamente sencilla, basada en un modelo físico de transferencia radiativa denominado WAK (Dymond *et al.*, 2001). Este modelo permite estimar un factor de estandarización de la reflectividad, suponiendo una orientación de referencia (visión vertical y 45° de ángulo cenital solar). En definitiva, se trata de encontrar un parámetro φ que permita convertir la reflectividad observada (ρ) en otra de referencia ($\hat{\rho}$):

$$\hat{\rho} = \varphi\rho \qquad \{6.44\}$$

El factor φ se calcula de forma distinta para el R e IRC del AVHRR (bandas 1 y 2, respectivamente). Los autores del método (Shepherd y Dymond, 2000), proponen:

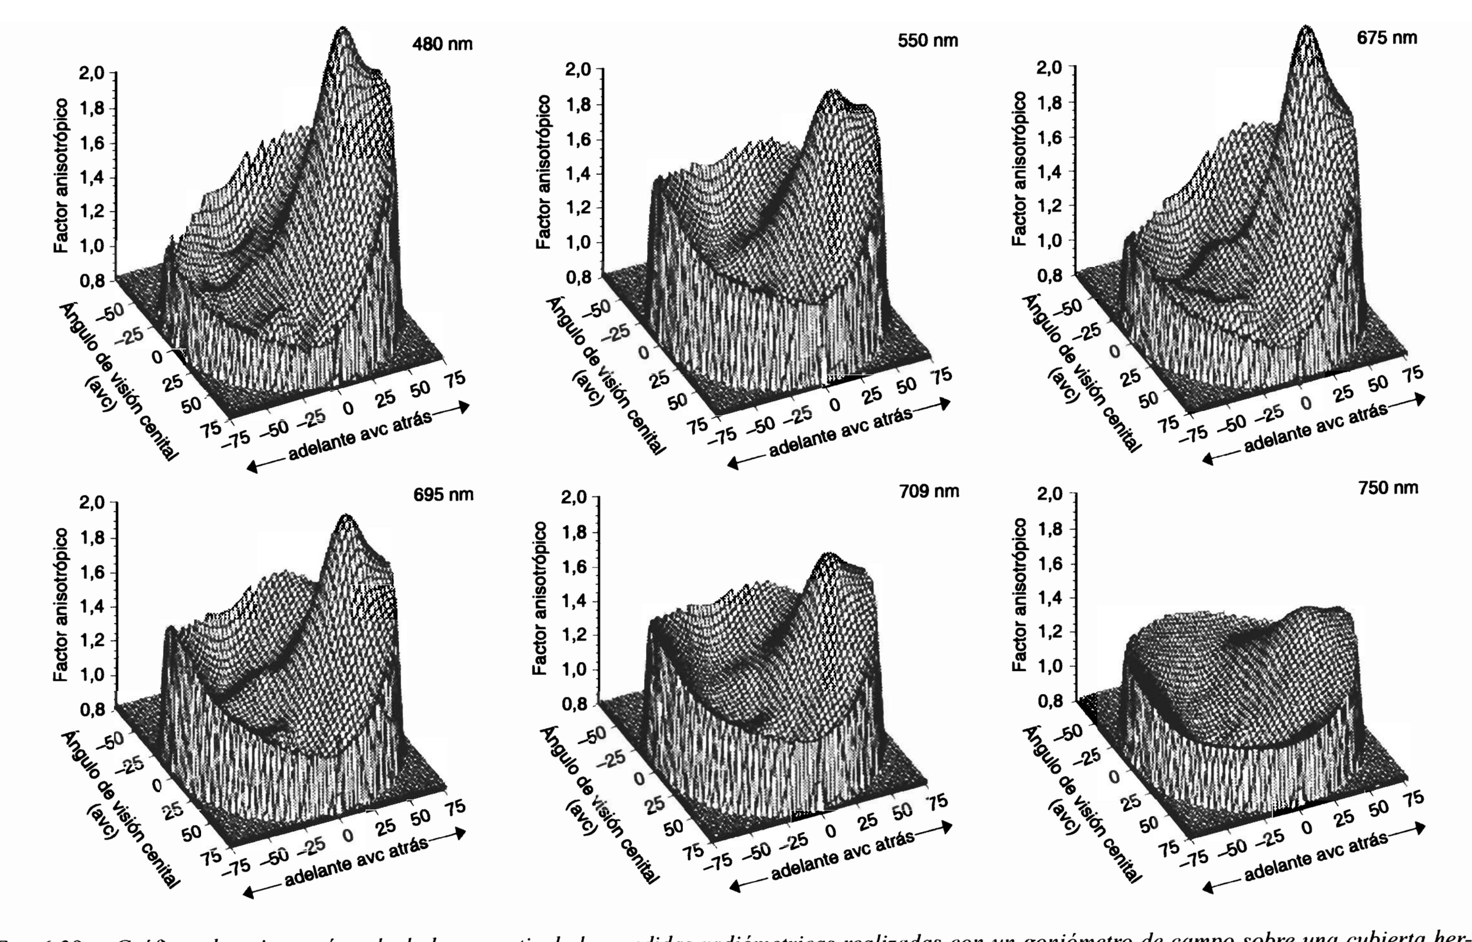


FIG. 6.39. *Gráficos de anisotropía calculados a partir de las medidas radiómetricas realizadas con un goniómetro de campo sobre una cubierta herbácea. (Sandmeier y Itten, 1999.)*

$$\varphi_R = \frac{\cos\theta_i + \cos\theta_e}{\cos\theta_{io} + \cos\theta_{eo}} \left[\frac{a + (\pi - a)e^{k\alpha_o^2}}{a + (\pi - a)e^{k\alpha^2}} \right] \quad \{6.45\}$$

y

$$\varphi_{IRC} = \frac{\cos\theta_i + \cos\theta_e}{\cos\theta_{io} + \cos\theta_{eo}} \left[\frac{\frac{8}{3\pi}(a + (\pi - a)e^{-k\alpha_o^2}) + H(\theta_{eo}\ w)H(\theta_{io}\ w) - 1}{\frac{8}{3\pi}(a + (\pi - a)e^{-k\alpha^2}) + H(\theta_i\ w)H(\theta_e\ w) - 1} \right] \quad \{6.46]$$

donde θ_i y θ_e indican los ángulos de incidencia y reflexión para la señal a corregir; θ_{io} y θ_{eo} los correspondientes a la visión de referencia (habitualmente 45° y 0°, respectivamente), α y α_o son los ángulos de fase (los que forman los rayos del sol con la posición del sensor, esto es la diferencia de acimut entre el sol y el satélite) de la señal a corregir y de la visión de referencia (en este caso 45°). El término *H* considera las reflexiones múltiples en el interior del dosel vegetal, y puede calcularse como:

$$H(\theta, w) = \frac{1 + 2\cos\theta}{1 + 2\cos\theta\sqrt{1 - w}} \quad \{6.47\}$$

para cada uno de los ángulos considerados (incidencia, reflexión, tanto de la señal detectada como de la de referencia). El resto de los parámetros: *w*, *a*, *k* son dependientes de la cubierta observada y se calculan a partir de su BRDF. Si no está disponible, w pueden estimarse a partir de la reflectividad de la hoja (ρ; $w = 2\rho$), y *a*, *k* de un análisis de regresión a partir de datos procedentes de dos órbitas distintas del AVHRR sobre las misma zona (en definitiva, tomadas con ángulos distintos), minimizando los residuales (R_i) de la siguiente expresión:

$$\frac{\rho_a}{\rho_b} - \frac{\cos\theta_{ia} + \cos\theta_{ea}}{\cos\theta_{ib} + \cos\theta_{eb}} \left[\frac{a + (\pi - a)e^{-k\alpha_a^2}}{a + (\pi - a)e^{-k\alpha_b^2}} \right] = R_i \quad \{6.48\}$$

donde ρ_a y ρ_b indican las reflectividades de una determinada cubierta extraídas de dos imágenes AVHRR (*a* y *b*) tomadas con distintos ángulos.

La figura 6.40 ofrece un ejemplo de la importancia de estos efectos direccionales en las imágenes AVHRR. Incluye una serie de valores de reflectividad para las bandas 1 y 2 extraídos de un sector de pinares en la provincia de Cuenca, así como los ángulos solares en el momento de la adquisición. Todas ellas son imágenes de la pasada diurna del NOAA-16 adquiridas entre las 13.00 y las 14.30 GMT. La dependencia del ángulo acimutal solar es bastante clara, observándose una tendencia cíclica en la reflectividad que se relaciona estrechamente con el ciclo orbital del satélite. Finalmente, conviene reseñar que entre los productos estándar del sensor MODIS se encuentra la reflectividad corregida del efecto bidireccional (producto MOD43) [Schaaf, 2002 #4303].

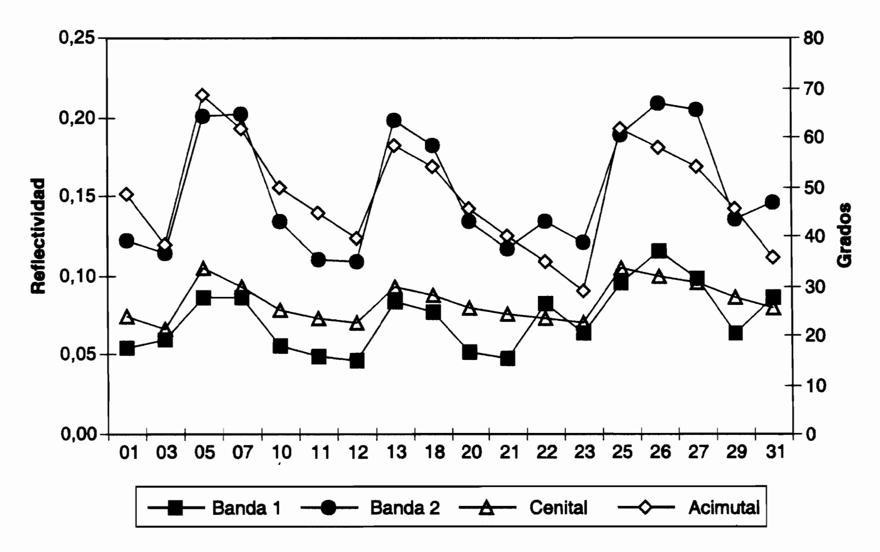


FIG. 6.40. *Serie temporal de valores de reflectividad extraídos a partir de los canales 1 y 2 del AVHRR en julio de 2001. Se incluyen los ángulos acimutal y cenital solar para observar el efecto que tienen sobre la señal detectada por el sensor.*

6.2.4. *Cálculo de temperaturas*

El cálculo de la temperatura de superficie es un proceso rutinario en aplicaciones oceanográficas, en donde este parámetro es clave para estudiar aspectos climáticos, así como en aplicaciones pesqueras. En lo que se refiere a temperaturas terrestres la investigación ha sido muy intensa en los últimos años ya que, pese a la dificultad de la estimación, se considera un elemento clave en los estudios de cambio climático global.

De modo esquemático (fig. 6.41), el proceso para el cálculo de temperatura se inicia con los ND detectados por el sensor. Al igual que en el espectro óptico, esos valores codifican un valor de radiancia, en este caso correspondiente al infrarrojo térmico. Aquí el objetivo no es encontrar la relación entre el flujo incidente en el suelo y el reflejado al sensor, sino entre el flujo emitido desde el suelo (L_{su}) y el recibido por el sensor (L_{sen}). Entre ambas magnitudes vuelven a interponerse los componentes de la atmósfera, que absorben y emiten su propia energía, distorsionando la radiancia recibida por el sensor.

Supuesto que elimináramos las influencias atmosféricas, bastaría conocer el flujo emitido en el suelo para saber su temperatura, ya que, como vimos, la radiación que emite un objeto es una función de su temperatura, de acuerdo a la ley de Planck {2.4}. Ahora bien, esta ley está definida para cuerpos negros. En consecuencia, el segundo problema en el cálculo de la temperatura radiativa, y además el más espinoso, es estimar la relación entre la emitancia de una superficie determinada y la que se produce en un cuerpo negro a la misma temperatura; en definitiva, es preciso conocer la emisividad de la cubierta para calcular su temperatura.

Tras este comentario, podemos ofrecer un esquema más cuantitativo para abordar ese cálculo. Seguimos el método propuesto por Coll *et al.* (1994), refinado por

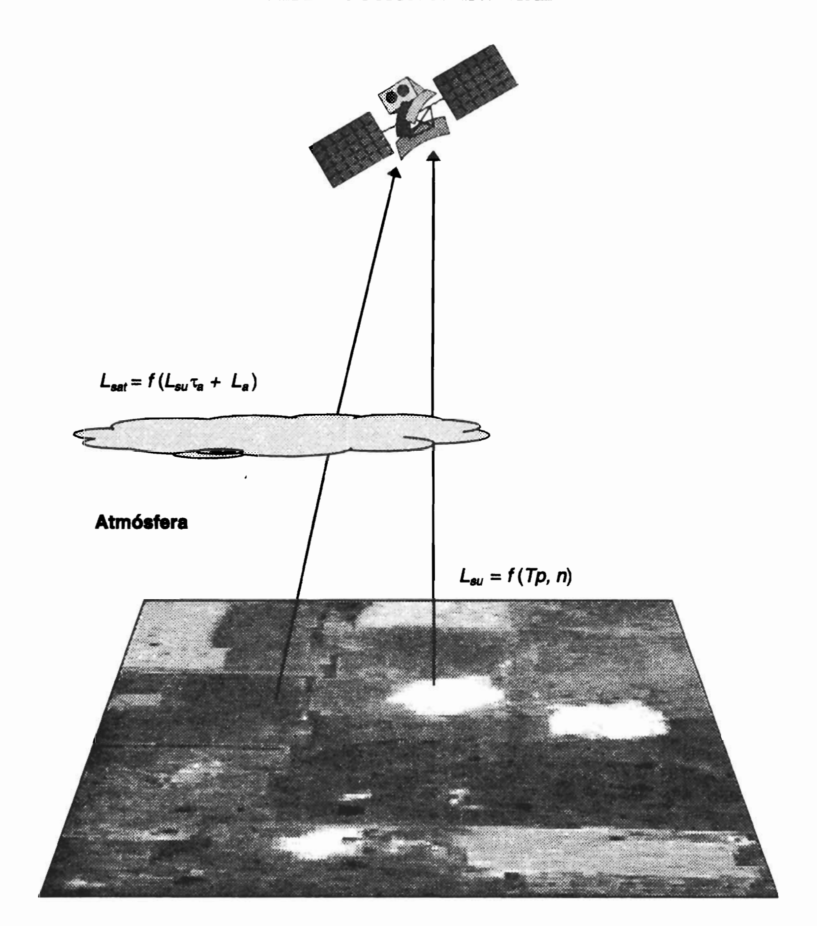


FIG. 6.41. *Esquema gráfico sobre el cálculo de la temperatura de superficie.*

Caselles *et al.* (1995) para obtener temperaturas de superficie (TS) a partir de imágenes AVHRR. Aunque también puede calcularse la TS desde imágenes Landsat-TM (Sobrino *et al.*, 2004), los sensores más empleados para esta tarea son el ATSR (Sobrino, 2000) y, más recientemente, el MODIS (Wan *et al.*, 2002), o los satélites geoestacionarios (Trishchenko, 2006). No obstante, el sensor AVHRR cuenta con una serie histórica de interés en esta línea, por lo que presentaremos el método de cálculo sobre este sensor. Según los autores, el método ofrece errores por debajo de 1,1 Kelvin para la determinación de la temperatura superficial del suelo y de 0,7 Kelvin para la superficie del mar (Caselles *et al.*, 1995).

Al igual que en el caso de las reflectividades, el primer paso en el cálculo de la temperatura es convertir los ND en radiancias. Puede usarse la misma fórmula antes vista {6.22}, si bien en este caso los coeficientes se cambian de línea a línea, aunque de modo poco significativo, de acuerdo al sistema de calibración que utiliza el AVHRR para sus dos bandas térmicas.

Una vez calculada la radiancia, puede estimarse la temperatura de brillo a partir de la inversión de la ecuación de Planck (Kidwell, 1991):

$$T^*(L) = \frac{c_2 v}{\ln(1 + c_1 v^3 / L_{sen,\, v})} \qquad \{6.49\}$$

donde T^* indica la temperatura de brillo en Kelvin para un determinado valor de radiancia L, v corresponde a la longitud de onda central de la banda térmica que estemos considerando (cm^{-1}), y $c1$ y $c2$ son constantes ($c1 = 1{,}1910659 \times 10 - 5$ *mW* $m^{-2}\ sr^{-1}\ cm^{-4}$ y $c2 = 1{,}438833$ *cm K*).

Para esta región del espectro, numerosos autores han sugerido basar la corrección atmosférica en los datos de la propia imagen. En este caso, se utilizan las diferencias de temperatura medidas en dos bandas cercanas del térmico para estimar la transmisividad atmosférica. Estos métodos se conocen con el nombre genérico de algoritmos de ventana partida *(split window)*, puesto que se necesita contar al menos con dos bandas en la ventana del IRT. La fórmula genérica de este tipo de correcciones sería:

$$T_s^* = T_i^* + A(T_i^* - T_j^*) - B \qquad \{6.50\}$$

siendo T_s la temperatura del suelo, y T_i y T_j las temperaturas de brillo en dos bandas contiguas del espectro. A y B son coeficientes dependientes del tipo de atmósfera. Otros autores han propuesto formulaciones similares para la observación biangular, esto es la adquisición de la misma banda del IRT pero con dos ángulos distintos, como ocurre con el ATSR (Sobrino, 2000).

Sin embargo, son más habituales las ecuaciones basadas en el algoritmo antes mencionado {6.50} ya que el sensor AVHRR ha sido la principal fuente de datos para obtener temperaturas de superficie en las últimas décadas. Para las condiciones promedio de nuestras latitudes, podemos utilizar los coeficientes propuestos por Caselles y colaboradores (Caselles *et al.*, 1995; Coll *et al.*, 1994) para la corrección atmosférica:

$$T_s^* = T_4^* + (1{,}0 + 0{,}58\,(T_4^* - T_5^*))\,(T_4^* - T_5^*) \qquad \{6.51\}$$

donde T_s^* indica la temperatura de brillo en la superficie; T_4^* y T_5^* son respectivamente las temperaturas de brillo de las bandas 4 y 5 del AVHRR.

El último paso para obtener la temperatura de superficie sería introducir la corrección de emisividad, que valora la eficiencia radiativa de una determinada superficie. La importancia de este factor se incorpora en la siguiente fórmula:

$$T_s^* = T_4^* + (1{,}0 + 0{,}58\,(T_4^* - T_5^*))\,(T_4^* - T_5^*) \qquad \{6.52\}$$

donde $\bar{\varepsilon}$ corresponde a la emisividad promedio de un píxel en las bandas 4 y 5 del AVHRR, y $\Delta\varepsilon$ a la diferencia de emisividad para el mismo píxel en esas dos bandas ($\Delta\varepsilon = \varepsilon_4 - \varepsilon_5$).

El problema más complejo a resolver aquí sería la estimación de la emisividad de la superficie, que dependerá del tipo de cubierta que esté observando el sensor. En muchas ocasiones esta información no estará disponible; incluso cuando tenga-

mos acceso a un mapa de cobertura del suelo de la zona observada, la estimación de la emisividad puede no ser muy correcta, por un lado por la variación estacional de las cubiertas vegetales. Por ejemplo, una zona de cultivos aparecerá como suelo descubierto en algunos períodos del año, y por otro, por la propia heterogeneidad del píxel, ya que aproximadamente en 1 km^2 (la mejor resolución espacial del AVHRR) puede haber una mezcla notable de tipos de cobertura y, por tanto, de emisividades. Lógicamente, esto no ocurre en la determinación de la temperatura del océano, en donde la emisividad es fácilmente calculable.

Una manera sencilla de estimar la emisividad para zonas no marinas sería asumir que un píxel está formado únicamente por suelo o vegetación, calculando una emisividad promedio en función de la proporción de superficie ocupada por estas dos cubiertas. Para estimar estas proporciones, Valor y Caselles (1996) sugirieron un método basado en los datos de la propia imagen, mas concretamente en las bandas del R e IRC, a partir de los cuales se pueden calcular índices de verdor (como veremos más adelante: 7.1.2). De acuerdo a este método, la proporción del píxel ocupado por vegetación puede obtenerse a partir de la relación entre su índice de vegetación (NDVI) y los mínimos y máximos de verdor detectados en una serie suficientemente larga de imágenes:

$$P_v = \frac{(1-(\mathrm{NDVI}/\mathrm{NDVI}_{min}))}{(1-(\mathrm{NDVI}/\mathrm{NDVI}_{min}))-k(1-(\mathrm{NDVI}/\mathrm{NDVI}_{max}))} \qquad \{6.53\}$$

donde NDVI_{max} y NDVI_{min} corresponden a los valores del índice de vegetación observados como máxima y mínima cubierta vegetal, respectivamente, y k es un factor de normalización:

$$k = (\rho_{2v} - \rho_{1v})/(\rho_{2s} - \rho_{1s}) \qquad \{6.54\}$$

siendo ρ_{2v} y ρ_{1v} las reflectividades de la vegetación en las bandas 2 y 1 del AVHRR, respectivamente, mientras ρ_{2s} y ρ_{1s} indican las reflectividades del suelo en esos mismos canales.

A partir de la proporción de cobertura verde puede calcularse la emisividad de cada píxel multiplicando esa proporción por la emisividad media de la vegetación (εv = 0,952 para herbáceos secos, 0,983 para árboles y 0,985 para herbáceos verdes y arbustos. También puede aplicarse un valor promedio global de 0,985), y el resto por la emisividad media del suelo descubierto (εs = 0,968 para suelos arenosos; 0,972 para limosos y 0,974 para arcillosos. Aquí el valor promedio sería 0,96). De esta forma, tendríamos (Caselles y Sobrino, 1989):

$$\varepsilon = \varepsilon_v P_v + (1 - P_v)\varepsilon_s + d\varepsilon \qquad \{6.55\}$$

y

$$\Delta\varepsilon = \Delta\varepsilon_v P_v + (1 - P_v)\Delta\varepsilon_s + d\Delta\varepsilon \qquad \{6.56\}$$

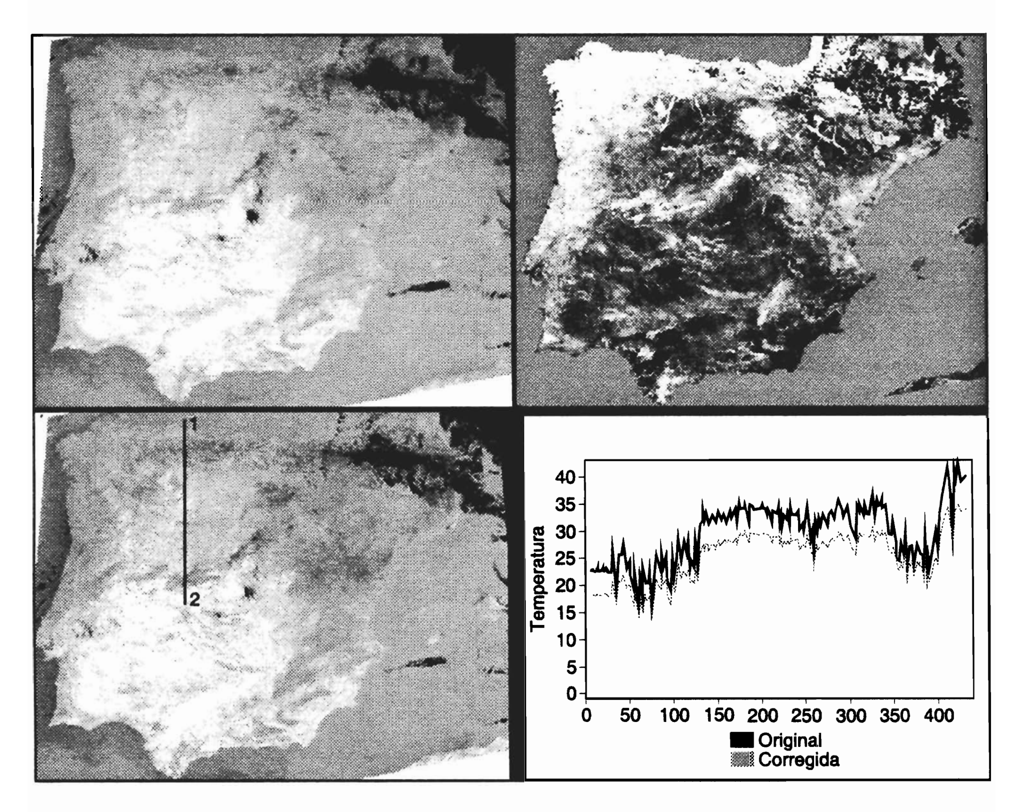


FIG. 6.42. *En la parte izquierda, temperatura de brillo (arriba) y corregida (abajo) de la imagen Ibérica01. En la derecha, emisividad (arriba), y perfil de temperaturas tomado desde el Cantábrico, hasta la Meseta sur.*

los términos $d\varepsilon$ y $d\Delta\varepsilon$ evalúan, respectivamente, los efectos de cavidad de ε y $\Delta\varepsilon$, y pueden determinarse a partir de las características geométricas de las plantas, aunque tienen una contribución muy pequeña (los valores oscilan entre 0,004 y 0,0025 para las cubiertas vegetales más habituales:) (Caselles *et al.*, 1995). Otros métodos para estimar la emisividad se basan en las medidas de campo o laboratorio, en relaciones empíricas, técnicas de inversión y medidas especiales (Sobrino, 2000, cap. 11).

En la figura 6.42 aparece un ejemplo de obtención de la temperatura de superficie para el conjunto de la Península Ibérica utilizando el método propuesto previamente sobre una imagen AVHRR. Hemos incluido la temperatura de brillo original de la banda 4, la imagen de emisividad y la temperatura del suelo, ya corregida de atmósfera y emisividad. Además, se señala un perfil, en el sentido norte-sur, que atraviesa la mitad norte de la Península, desde el Cantábrico hasta el Valle del Tajo. Se observa el efecto de la corrección atmosférica y de emisividad sobre la temperatura final, con amplitudes que superan los 7 °C en algunos sectores. Por otro lado, la tendencia al aumento de la temperatura, de norte a sur, es bastante evidente, así como los accidentes montañosos que atraviesa el perfil, como la Cordillera Cantábrica y el Sistema Central, claramente diferenciados por el brusco decremento de la temperatura frente a los valles pre-cordilleranos (12-15 °C en la Cantábrica y unos 18-20 °C en el Sistema Central).

La observación térmica tiene gran interés para el seguimiento de fenómenos que afectan a la vegetación, como ya vimos en el capítulo 2. La temperatura de superficie está inversamente relacionada con el vigor vegetal, ya que la evapotranspiración libera calor y, en consecuencia, reduce la temperatura de la masa vegetal frente al suelo descubierto. Por tanto, la evolución temporal de la temperatura de superficie nos permite estimar las condiciones de vigor o estrés de la planta, de cara a estudios de rendimiento agrícola (Caselles y Sobrino, 1989), de evapotranspiración (Sandholt *et al.*, 2002) o de riesgo de incendios (Vidal *et al.*, 1994), además de su clara aplicación a estudios oceanográficos o pesqueros (Barreto, 2000). En el ámbito de los estudios de cambio climático, el análisis de las tendencias temporales de temperatura resulta especialmente significativo, permitiendo una observación sistemática y de grandes extensiones [National Research Council, 2007 #5010].

6.2.5. *Detección de nubes*

La cubierta nubosa supone el principal obstáculo para el análisis de la variación a corto plazo de una determinada superficie terrestre cuando estemos trabajando con sensores ópticos o térmicos. Puesto que la presencia de nubes introduce una severa distorsión en las series temporales de imágenes, en muchas ocasiones resulta imprescindible aplicar alguna técnica que permita discriminarlas, ya sea para aislar ese sector de otros análisis, cuando el interés se centra en la cubierta que está debajo de la nube, ya para retener estos valores, cuando precisamente el interés es la propia nube.

El problema de discriminación de nubes es una tarea muy frecuente en teledetección que ha recibido la atención de numerosos autores. Aquí lo trataremos únicamente con un enfoque práctico, de cara a proponer algunas soluciones para aislar los píxeles nubosos de posteriores tratamientos.

Una de las formas más eficaces de discriminar las nubes se apoya en la interpretación visual (Cracknell, 1997), ya que el intérprete puede incluir una serie de criterios espectrales y espaciales que son complicados de definir en términos digitales. Ahora bien, este método también presenta una serie de inconvenientes (Simpson y Gobat, 1996): se trata de una labor tediosa, ya que hay que visualizar las imágenes para detectar las nubes; no es estadísticamente reproducible para otros lugares geográficos ni otros investigadores, y requiere de conocimiento y experiencia en fotointerpretación.

Por estas razones, habitualmente los criterios de detección de nubes se basan en la aplicación de distintas técnicas de análisis digital. Entre ellas, son más numerosas las basadas en la aplicación de una serie de test consecutivos, que permiten discriminar un píxel como nuboso cuando cumple una serie de condiciones, ya sean espectrales (lo más habitual), espaciales o una mezcla de las dos (Bastarrika, 2000). Otros criterios propuestos se basan en técnicas de clasificación no supervisada. Por ejemplo, el método ASMC, de agrupamiento y separación iterativa, ideado por (Simpson y Gobat, 1996), o en índices espectrales, como el *tasseled cap*, que luego veremos: (Labuto, 1991).

El principal problema de los algoritmos de umbrales múltiples es establecer unos valores críticos que sean de validez universal. Dada la gran variedad de tipos de nubes, espesores y áreas donde se sitúan, resulta complejo establecer unos lími-

tes bien adaptados a cualquier situación. Posiblemente el intérprete tendrá, en algunas ocasiones, que adaptar los umbrales propuestos hacia valores más o menos conservadores, según se pretenda reducir al máximo los errores de omisión (nubes que no se detecten) o de comisión (áreas no nubladas que se etiqueten como tales). Si el objetivo es eliminar con toda seguridad las nubes, los límites pueden ser bastante amplios, mientras si se pretende reducir los errores de comisión será necesario restringir más rigurosamente esos umbrales.

Uno de los algoritmos de umbrales múltiples más utilizados en la detección de nubes es el propuesto por Saunders y Kriebel (1988). Se basa en 5 pruebas para imágenes diurnas y otras 5 para imágenes nocturnas que se aplican píxel a píxel, determinando si está despejado, parcial o totalmente nublado. Por ejemplo, para las imágenes diurnas estos cinco test son (fig. 6.43) (Bastarrika, 2000):

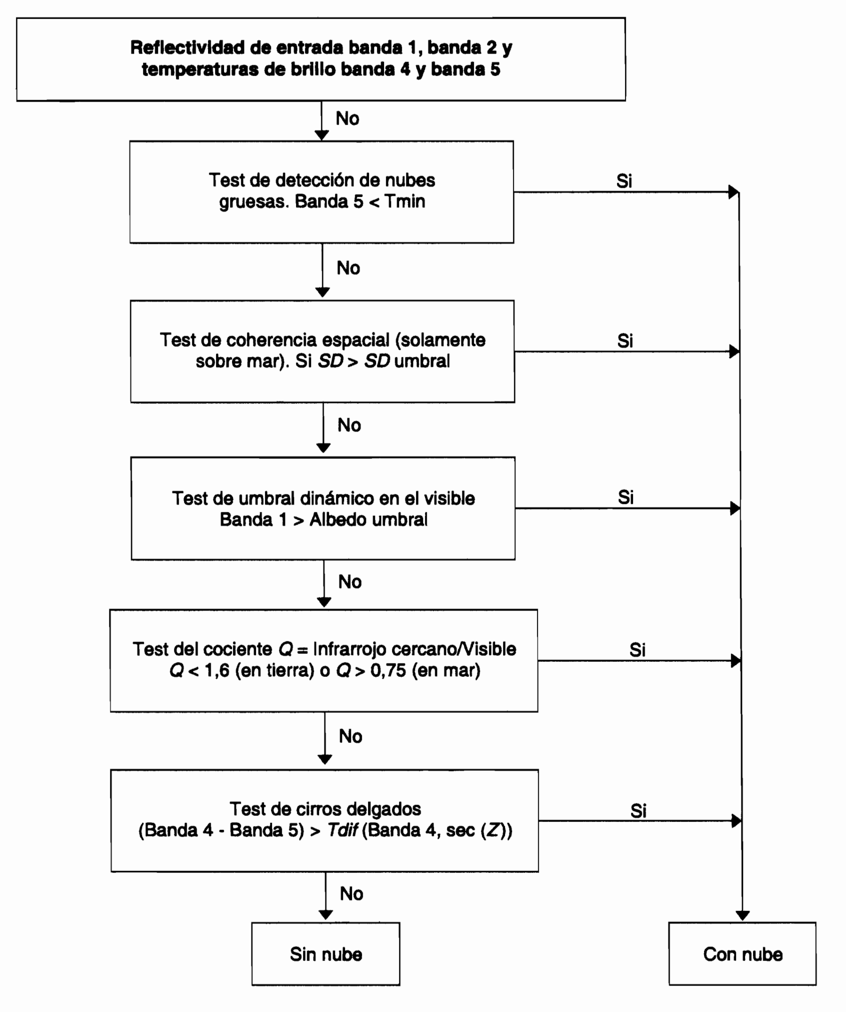


FIG. 6.43. *Esquema del algoritmo de discriminación de nubes (adaptado de Saunders y Kriebel, 1988).*

1. *Prueba del umbral térmico.* Se aplica para la determinación de nubes gruesas a partir de un umbral de temperatura de brillo en 12 µm (banda 5 del AVHRR). La temperatura de brillo de esa banda es más adecuada para detectar nubes que la ofrecida por la banda 4 (11 µm) porque las nubes tienen una mayor profundidad óptica en esas longitudes de onda. Si la temperatura es menor que un umbral absoluto, el píxel se identifica como nuboso. Este método, lógicamente, usa diferentes umbrales para tierra y mar. Para determinar el umbral se identifican en la imagen las zonas más frías libres de nubes tanto en tierra como en mar. A la temperatura de esas zonas más frías se les resta una cantidad (normalmente mayor que 2 °C) y así puede obtenerse el umbral deseado, uno para mar y otro para tierra. El hecho de seleccionar un único umbral puede ser correcto para terrenos llanos u ondulados, pero hay que tener mucho cuidado al establecer umbrales en una imagen muy extensa, donde exista terreno montañoso: el decremento de la temperatura con la altitud puede provocar la clasificación de píxeles fríos, pero libres de nubes, como nubosos. Este problema puede solventarse utilizando umbrales dinámicos, por ejemplo, basados en compuestos multitemporales de temperaturas.

2. *Prueba de coherencia y uniformidad espacial.* Intenta comparar la temperatura de brillo de un píxel en la banda 4 con la de su entorno, basándose en la desviación estándar (SD) de una ventana de 3 × 3 píxeles. La idea de este criterio es que la variabilidad de la temperatura de brillo sobre píxeles contaminados por nubes debería ser mayor que para píxeles libres de nubes. Los umbrales de la desviación estándar son empíricamente determinados y se mantienen constantes para todo el área.

3. *Prueba del umbral de reflectividad dinámica.* Casi todas las nubes tienen alta reflectividad en el visible e IRC, mucho mayor que la correspondiente a la superficie terrestre y marina. En zonas terrestres, la reflectividad en la banda 1 tiende a ser menor que en la 2; por tanto, el contraste tierra-nube será mucho más acentuado en el banda 1. Sin embargo, en el mar suele utilizarse la 2, debido a que está mucho menos afectada por los aerosoles y la dispersión *Rayleigh*.

4. *Prueba del cociente entre las reflectividades de las bandas 2 y 1 (Q).* Los valores de este cociente para píxeles nublados son cercanos a 1 debido a que los efectos de dispersión (dispersión Mie) son parecidos para ambas bandas. Sobre tierra (zonas con vegetación) los valores de Q son superiores a la unidad debido a la mayor reflectividad en el IRC que en el VIS. Sobre el mar, en cambio, ocurre lo contrario. Así, se determinan dos umbrales; sobre tierra si $Q < 1,6$ se supone que el píxel es nuboso, mientras que sobre mar si $Q > 0,75$ el píxel también se supone nuboso. Este método no trabaja bien en áreas con reflejos solares, donde el valor Q es cercano a 1 y, por tanto, es similar a los valores obtenidos para las nubes.

5. *Prueba de la diferencia de temperaturas de brillo (banda 4-banda 5).* Finalmente, el quinto criterio propuesto por Saunders y Kriebel utiliza la diferencia de temperatura de brillo entre los bandas 4 y 5. La variación de las emisividades de las nubes con la longitud de onda hace que haya diferencias de temperatura entre ambas bandas. Estas diferencias de temperatura pueden usarse, por ejemplo, para detectar cirros bastante delgados porque las nubes tienen diferentes emisividades a diferentes longitudes de onda. Sobre nubes, las diferencias de temperatura de brillo pueden ser de hasta 6 K. Las diferencias sobre píxeles libres de nubes, sin embargo, suelen ser

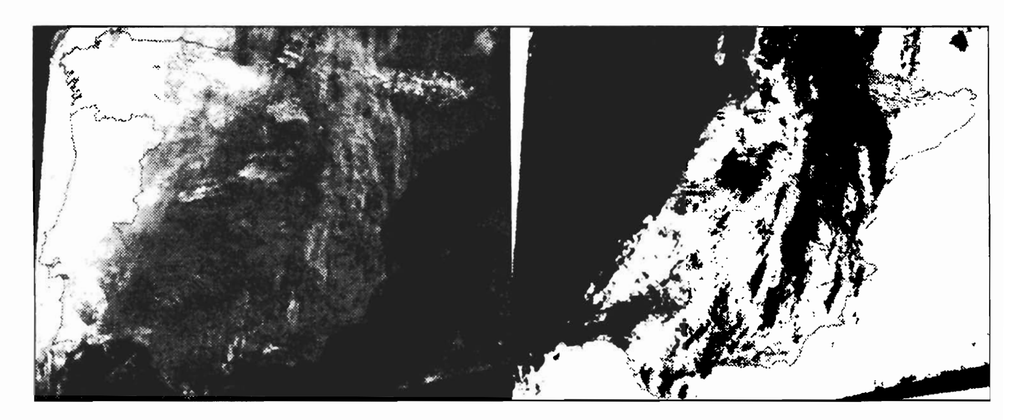


FIG. 6.44. *Ejemplo de aplicación del algoritmo de Saunders y Kriebel a una imagen AVHRR de la Península Ibérica tomada el 12 de enero de 1999. (Cortesía Aitor Bastarrika.)*

menores (a menudo menor que 1 K), aunque dependerá de la cantidad total de vapor de agua en la atmósfera y del ángulo cenital. Saunders y Kriebel proponen una serie de umbrales para estas diferencias, basados en el ángulo cenital solar.

La figura 6.44 presenta un ejemplo de la aplicación de estas pruebas sucesivas sobre una imagen AVHRR de invierno que incluye toda la Península Ibérica, con cierta cobertura nubosa. Resulta evidente la buena discriminación de las nubes que facilita el algoritmo de Saunders y Kriebel, si bien en este caso se ha modificado un poco los criterios para establecer los umbrales. Aquí, en lugar de valores absolutos, se ha primado las diferencias de contexto espacial frente a imágenes sintéticas de temperatura máxima mensual, de tal manera que en cada píxel se establece el umbral por relación a los valores de temperatura máximos que se hayan observado en ese píxel (y su vecindad) en el período mensual que se considere (Bastarrika, 2000). Recientemente, se han propuesto otros algoritmos automáticos de detección de nubes, que permiten delimitar porcentajes de cobertura o niveles de probabilidad [Khlopenkov, 2007 #4951]. También se han presentado algoritmos más refinados en el contexto del análisis de imágenes MODIS. Este sensor, proporciona una mayor facilidad para distinguir diversos tipos de nubes, gracias a su buena resolución espectral y calibración radiométrica consistente [Ackerman, 1998 #4362].

6.3. CORRECCIONES GEOMÉTRICAS

6.3.1. *Introducción*

Las correcciones geométricas de la imagen incluyen cualquier cambio en la posición que ocupan los píxeles que la forman. Gracias a tratarse de un formato digital, esta transformación puede basarse en funciones numéricas, que permiten modificar muy flexiblemente la geometría de la imagen. La expresión general de este tipo de funciones sería:

$$f(c') = f_1\ (c,\ l); f\ (x,\ y)$$

$$f(l') = f_2\ (c,\ l); f\ (x,\ y)$$

Esto es, las coordenadas columna y línea (c' y l') de la imagen corregida son función de las coordenadas columna y línea de la imagen de entrada (c, l) o de las coordenadas del mapa al que se pretende superponer la imagen (x, y). Por tanto, esta transformación puede emplearse tanto para corregir cartográficamente una imagen, como para superponer dos o más imágenes entre sí. En el primer caso, se pretende encontrar una relación que transfiera los ND de la imagen a su posición cartográfica, en la proyección requerida (habitualmente la *Universal Transversal de Mercator*, UTM, estándar en España y en la mayor parte de los países vecinos). Esto permite que la imagen resultante pueda combinarse con información auxiliar o integrarse a un SIG (cap. 9). En el segundo caso, la transformación geométrica de la imagen tiene por objetivo ajustarla a otra imagen que se considera como referencia, normalmente con objeto de realizar estudios multitemporales (cap. 7.3) o mosaicos para obtener una cobertura más completa del territorio.

La corrección geométrica de imágenes puede abordarse de acuerdo a dos procedimientos. En el primero, denominado corrección orbital, se pretende modelar aquellas fuentes de error geométrico conocidas, a partir de aplicar transformaciones inversas a las que realiza el sensor en el momento de la adquisición. Para ello, es preciso disponer, con bastante precisión, de las características orbitales de la plataforma y de las especificaciones del sensor. Gracias a ellas pueden corregirse errores sistemáticos, como son los derivados de la rotación o curvatura terrestre y de la inclinación de la órbita. El segundo enfoque resulta más empírico. Se trata de modelar el error geométrico de la imagen a partir de una serie de puntos con coordenadas conocidas, que se denominan puntos de control. En este caso, el error se modela inductivamente, ya que en las funciones de transformación se incluyen simultáneamente todas las fuentes de error, asumiendo, como es lógico, que esos puntos sean suficientemente representativos de la deformación geométrica que tiene la imagen.

Ambos métodos tienen sus ventajas e inconvenientes. El primero es mucho más automático, pues los datos orbitales se reciben directamente con las imágenes y apenas se requiere intervención humana del operador. Resulta, además, muy adecuado cuando el sensor no proporciona información fiable para localizar los puntos de control, ya sea por tratarse de imágenes marinas (sin referencias visuales), ya con cobertura de nubes o con una resolución tan grosera que apenas puedan identificarse rasgos cartográficos. Éste es el procedimiento habitualmente empleado para corregir imágenes de baja resolución, tanto polares como geoestacionarios, aunque es más sencillo en estos últimos. Su principal inconveniente es la escasa precisión cuando la telemetría del satélite no es muy exacta (en el caso de los satélites polares: AVHRR, MODIS, Vegetation, Seawifs, Fen Yung) o cuando la imagen incluye errores aleatorios, como los debidos a movimientos imprevistos del sensor o al relieve local, que pueden llegar a suponer desplazamientos del orden de ±5 píxeles (Ho y Asem, 1986). No obstante, con modelos más elaborados, que pueden incluir algún punto de control terrestre, el orden de precisión se eleva hasta ±1 píxel (Emery *et al.*, 1989; Rosborough *et al.*, 1994). Las plataformas más modernas inclu-



FIG. 1*. *Imágenes Quickbird de Nueva Orleáns (USA) tomadas antes y poco después de la inundación provocada por el huracán Katrina en agosto de 2005 (www.digitalglobe.com).*

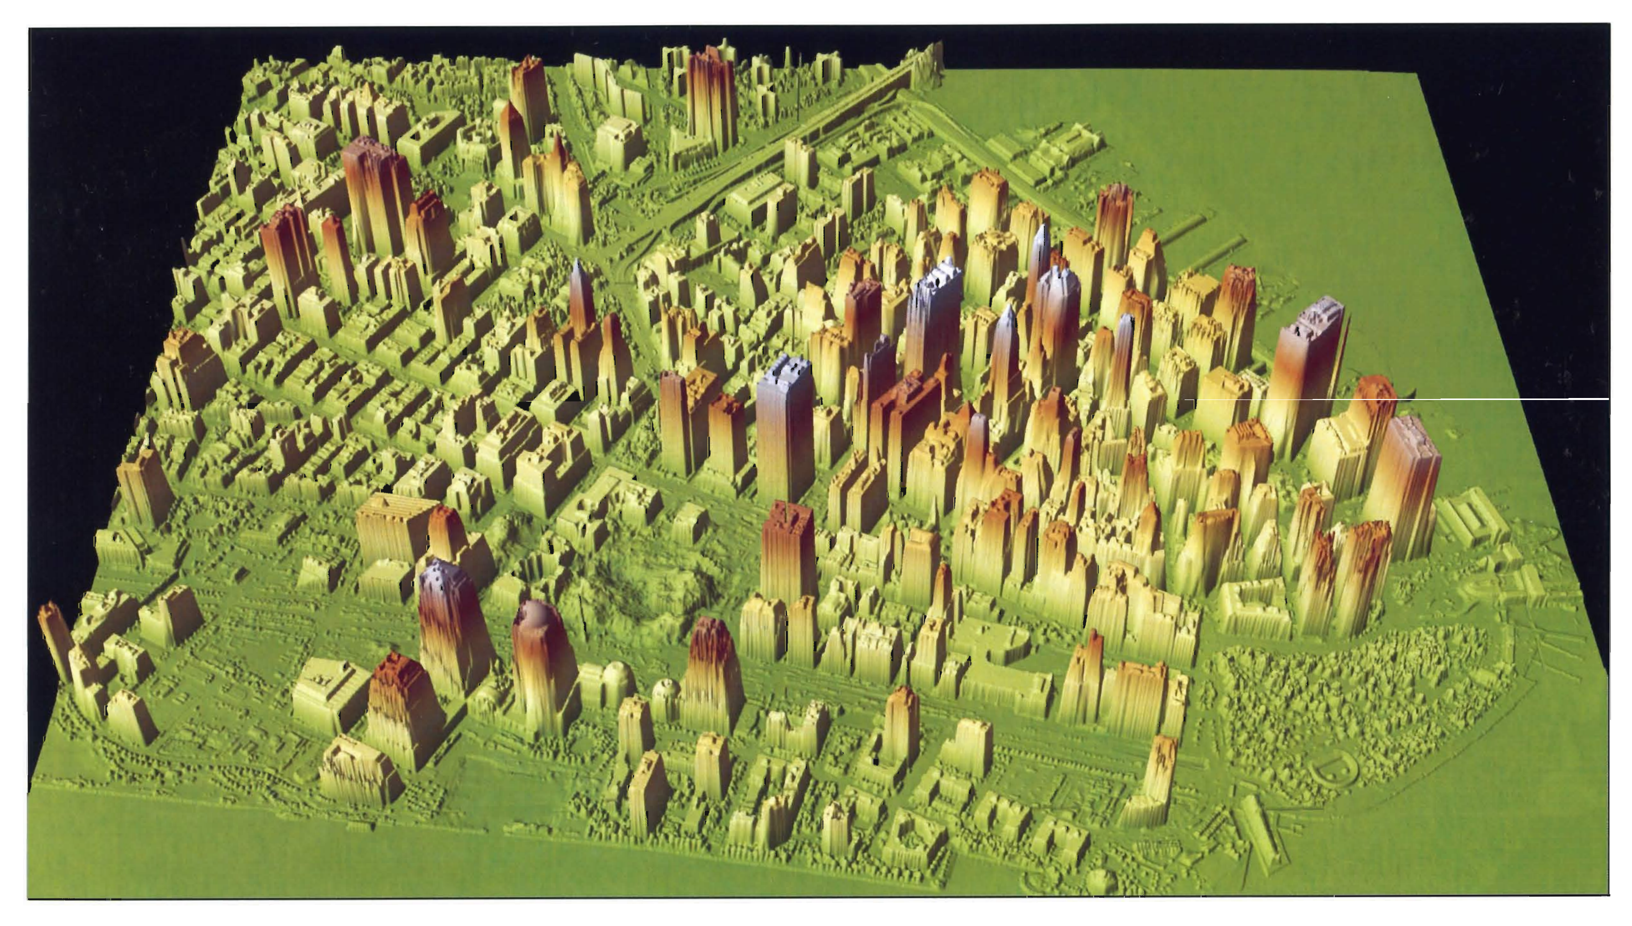


FIG. 2*. *Reconstrucción de alturas en la isla de Manhattan a partir de un lídar aerotransportado El vuelo se realizó el 23 de septiembre de 2001 (cortesía: NOAA/U.S.Army JPSD, www.noaa.gov).*



FIG. 3*. *Composición en color de una imagen radar de la isla de Tenerife, correspondiente a la misión SIR-C/X-SAR del Endeavour (11-10-1994). En rojo aparece la banda L (polarización HH); en verde la banda L (polarización HV), y en azul la banda C (polarización HV). Cortesía NASA (http://visibleearth.nasa.gov).*



FIG. 4*. *Relieve sombreado de África a partir del modelo digital generado por la misión SRTM (http://photojournal.jpl.nasa.gov/catalog/PIA04965).*

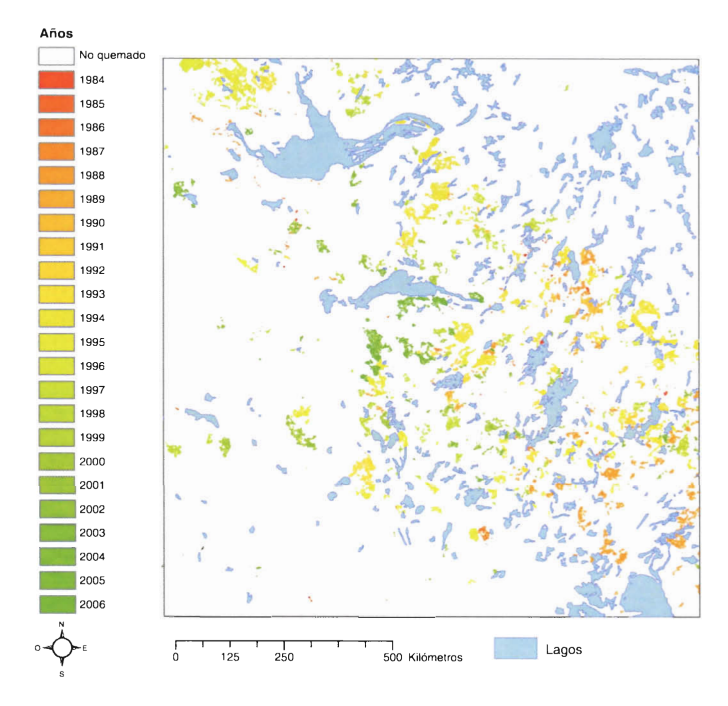


FIG. 5*. *Cartografía de áreas quemadas en el bosque boreal canadiense realizada a partir de una serie temporal de imágenes NOAA-AVHRR (tomado de Chuvieco* et al., *2008a).*



FIG. 6*. *Imagen del sensor SEVIRI, adquirida por el Meteosat-8 el 9 de mayo de 2003 que muestra el disco visible de la Tierra adquirida. La composición en color corresponde a las bandas del IRC (1,6 μm), R (0,8 μm) y V (0,6 μm), realzadas digitalmente (Fuente EUMETSAT: http://www.eumetsat.int/Home/Main/Image_Gallery/PR_Images/Fulldisk_Images/index.htm).*



FIG. 7*. *Imagen Aster del Estrecho de Gibraltar adquirida el 5 de julio de 2000. Cortesía NASA (http://visibleearth.nasa.gov).*

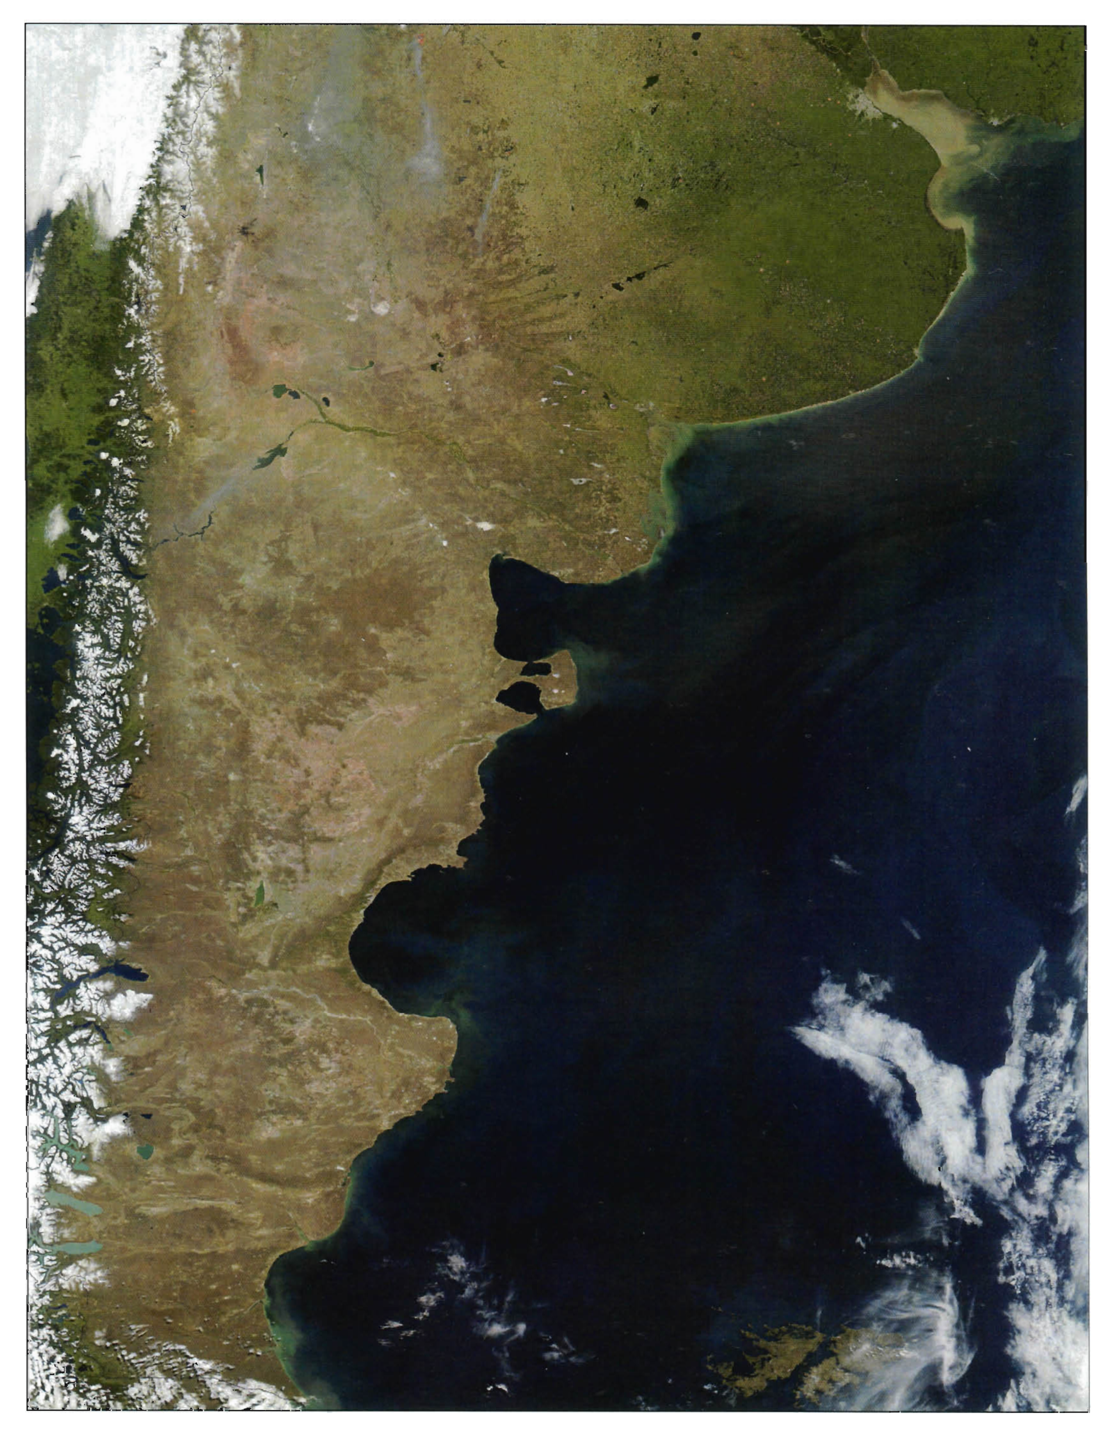


FIG. 8*. *Imagen Terra-MODIS del Cono Sur adquirida el 2 de noviembre de 2003. Composición en color real de los canales reflectivos sobre los que aparecen algunos incendios activos. La imagen se extiende desde Buenos Aires (al norte) hasta el límite con Tierra del Fuego. Fuente: http://visibleearth.nasa.gov.*



FIG. 9*. *Imagen Envisat-MERIS adquirida el 9 de agosto de 2006 que muestra los incendios activos en Galicia y Norte de Portugal. Fuente: ESA (http://earth.esa.int/).*

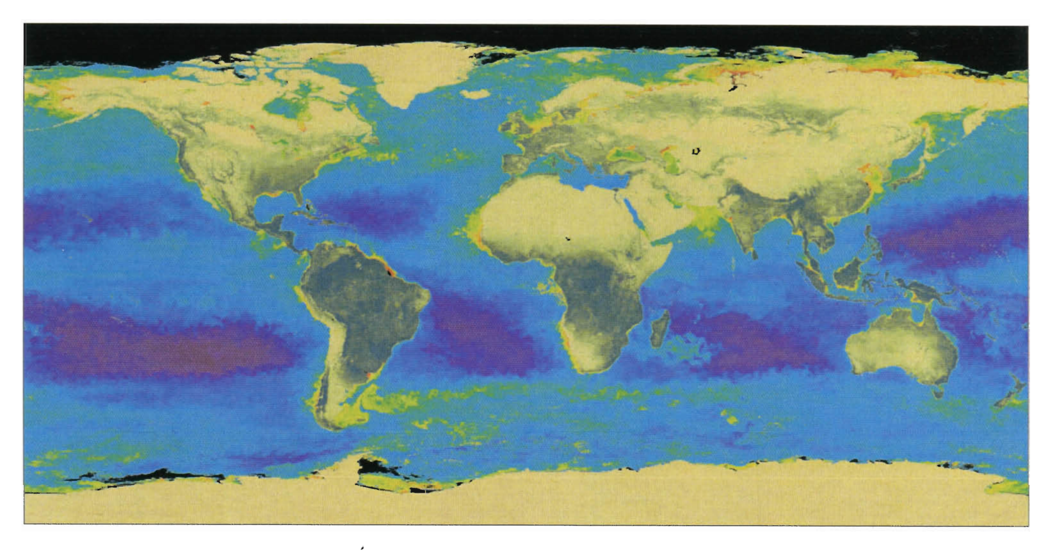


FIG. 10*. *Imagen de clorofila acuática y verdor terrestre obtenida a partir de datos Seawifs. (Fuente: http://visibleearth.nasa.gov/view_rec.php?id=1664).*

FIG. 11*. *Proceso de formación de las composiciones coloreadas.*

FIG. 12*. *Diversas composiciones en color sobre la imagen Madrid02.*

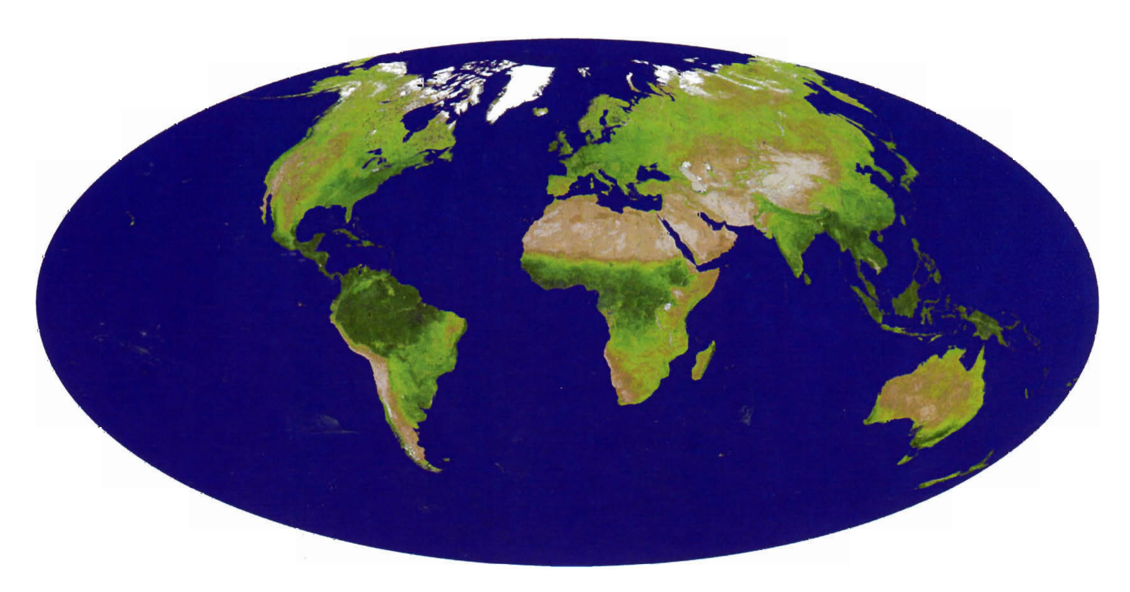


FIG. 13*. *Imagen global del EVI a partir de datos MODIS (Fuente: http://visibleearth.nasa.gov/).*

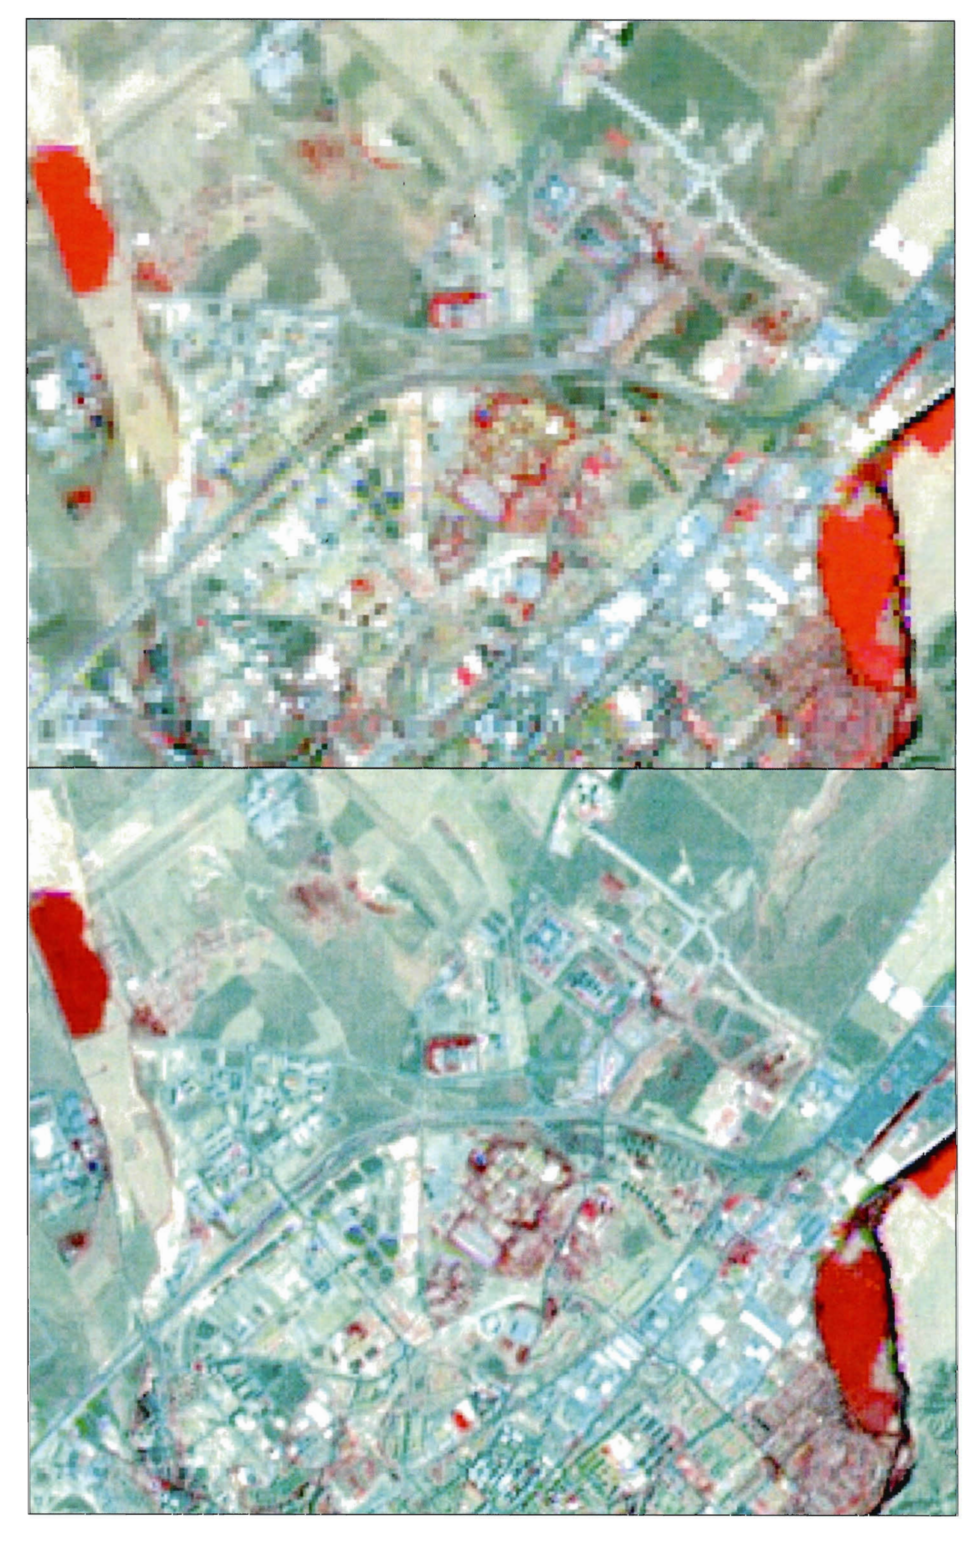


FIG. 14*. *Fusión del canal pancromático ETM y una composición en color 4/5/3 sobre una imagen de Alcalá de Henares: original (arriba), resultado de la fusión (abajo).*

FIG. 15*. *Clasificación supervisada de máxima probabilidad sobre la imagen Torrel00: (1) Agua; (2) Urbano; (3) Pinar; (4) Pastizal; (5) Matorral-Encinar; (6) Suelo descubierto (7) Cultivos.*

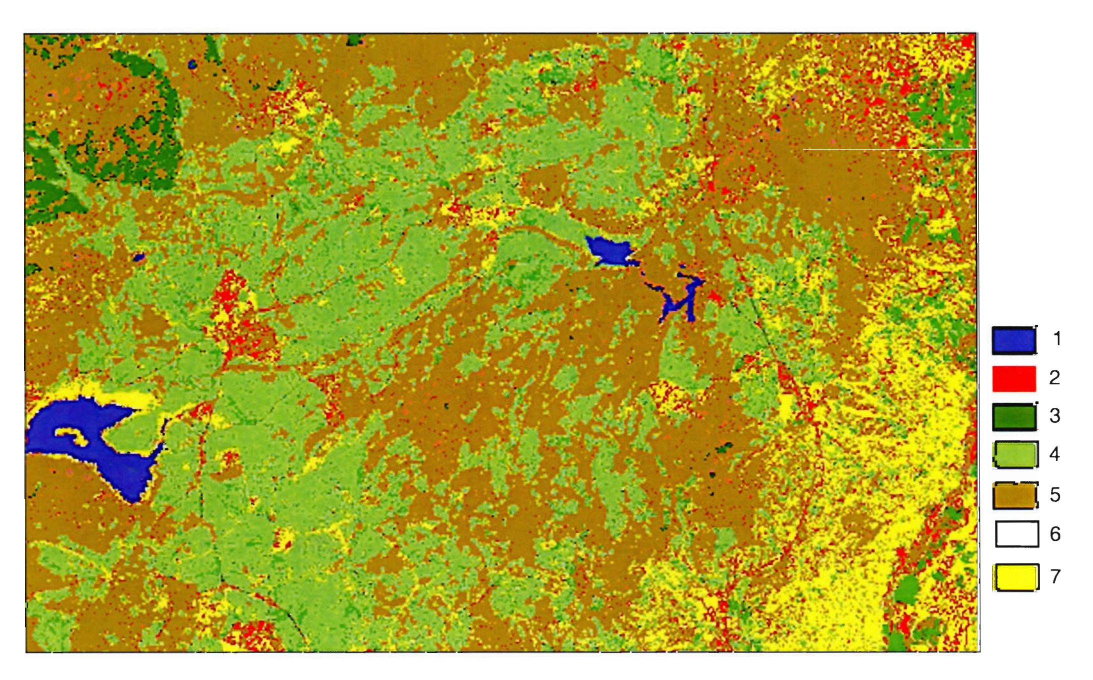


FIG. 16*. *Clasificación supervisada por redes neuronales sobre la imagen Torrel00 (la clave de color es igual a la figura anterior).*

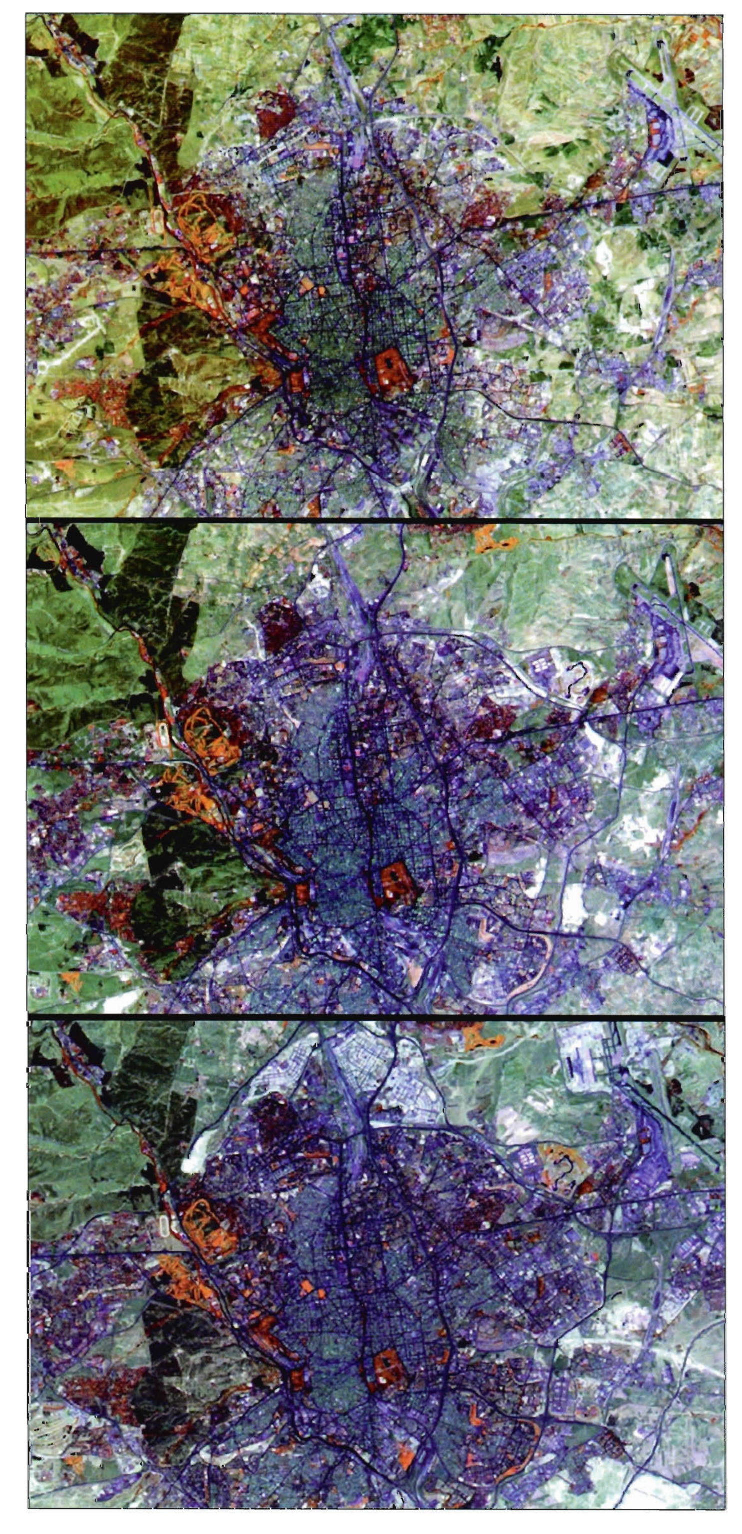


FIG. 17*. *Cambios en la ciudad de Madrid a partir del análisis temporal de imágenes Landsat-TM. De arriba abajo, 1984, 1992 y 2002.*

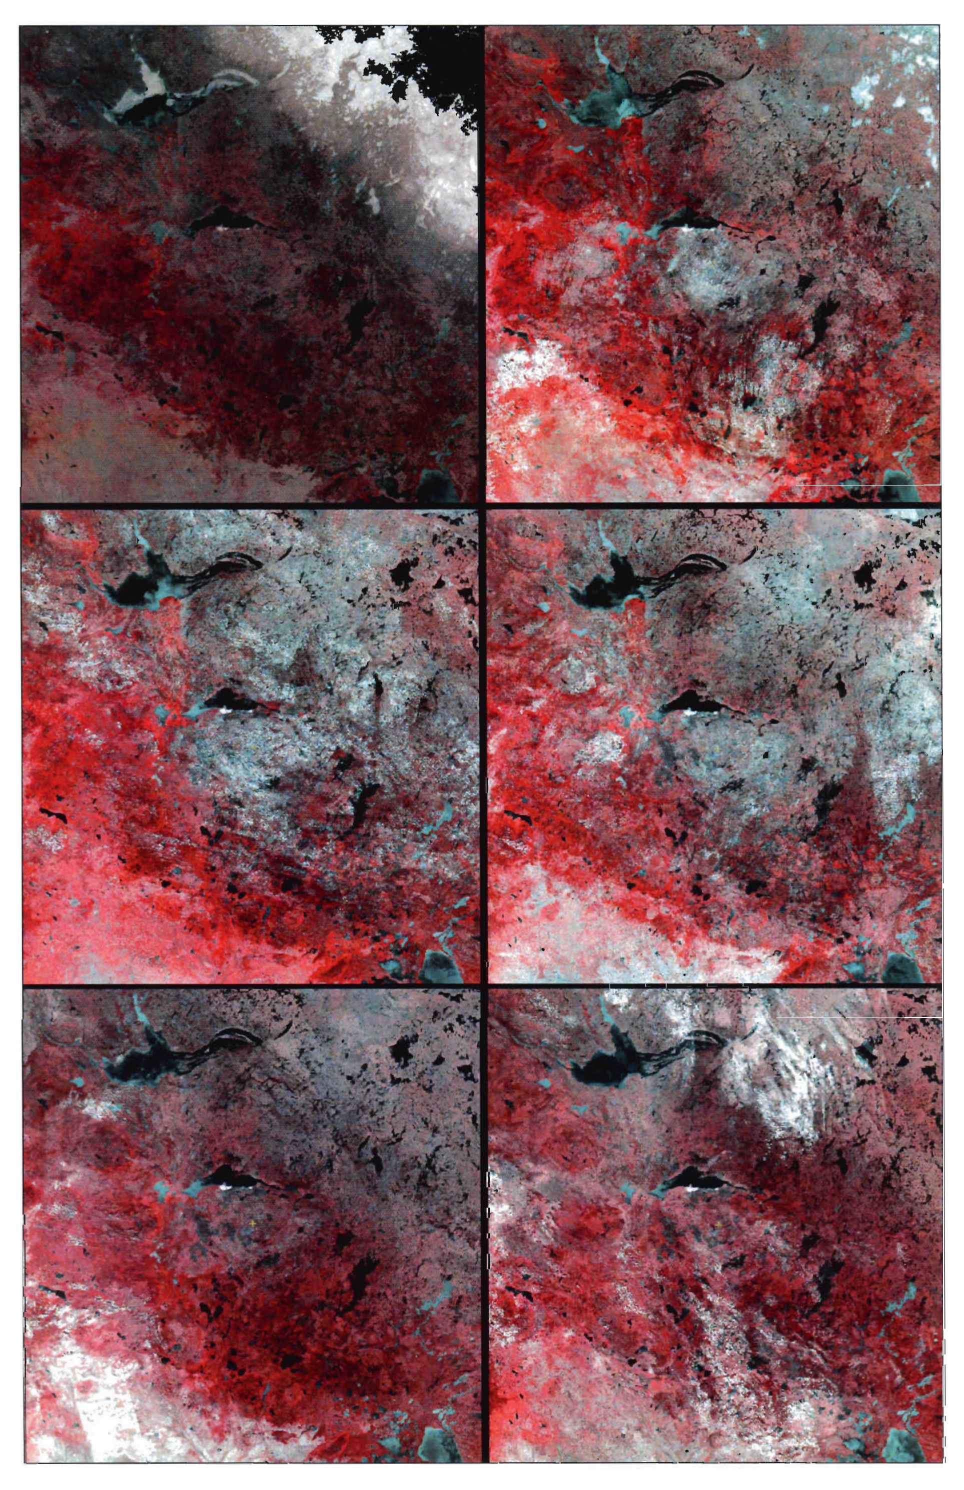


FIG. 18*. *Imágenes AVHRR de un amplio sector del norte de Canadá, comprendido entre las provincias de Alberta, Saskatchewan, Manitota y Northwestern Territories. Aparece una secuencia de imágenes adquiridas en 2006 por el NOAA-18. De arriba a abajo y de izquierda a derecha: inicios de mayo, junio, julio, agosto, septiembre y fines de septiembre.*

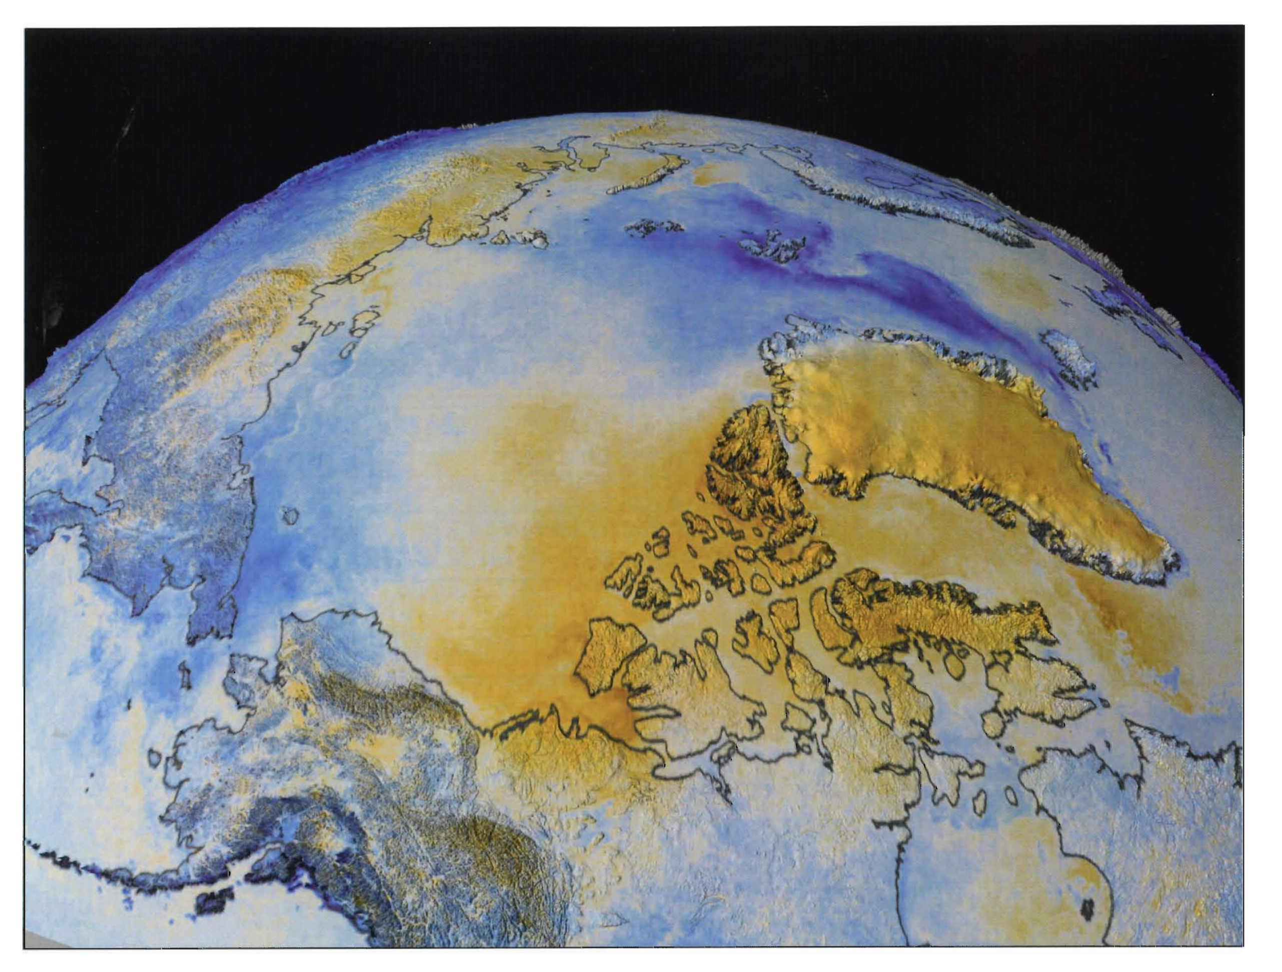


FIG. 19*. *Anomalías térmicas en el Ártico entre 1982 y 2002 (tonos rojos indican calentamiento y azules enfriamiento, blancos no cambio). Fuente: http://visibleearth.nasa.gov/*

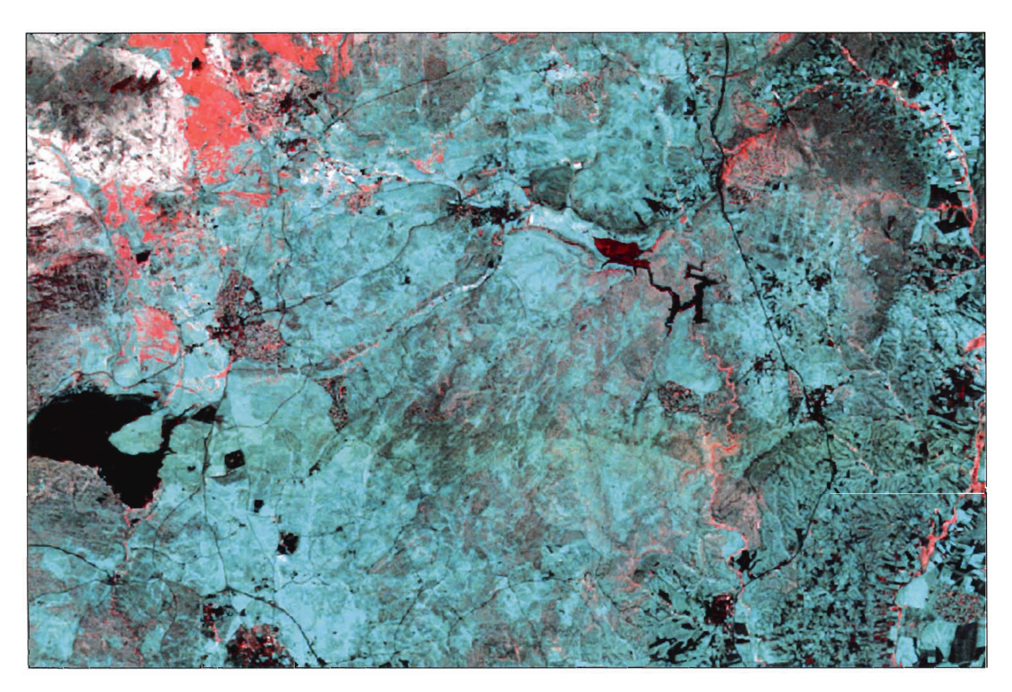


FIG. 20*. *Composiciones en color multitemporales a partir del NDVI de la imagen Torrel00. Rojo, verano de 1999; azul y verde, primavera de 2000.*

FIG. 21*. *Efecto de la resolución espacial sobre el patrón espacial de imágenes. Imágenes Landsat-TM (arriba) y NOAA-AVHRR (abajo), tomadas antes y después del incendio de Buñol (agosto de 1991).*

yen sistemas de navegación mucho más refinados que permiten mejorar notablemente estas correcciones orbitales (caso del SPOT-4). Por su parte, el método de puntos de control resulta bastante tedioso, pues requiere una notable intervención humana para localizar adecuadamente esos puntos, pero ofrece una alta precisión cuando se trabaja sobre zonas e imágenes en donde es clara la identificación de rasgos comunes a la cartografía básica.

6.3.2. *Corrección a partir de modelos orbitales*

Como se ha indicado, estas correcciones resultan muy adecuadas para sensores de baja resolución o que trabajan sobre áreas marinas, en donde resulta muy complicado buscar puntos de control. El creciente interés por el empleo de imágenes de sensores de observación global ha subrayado el papel de estas correcciones, ya que son paso obligado para su análisis. Habitualmente, al aplicar correcciones orbitales se utiliza el término «navegación» de la imagen (Emery *et al.*, 1989), ya que se pretende localizar sobre una malla geográfica cada uno de los píxeles que la forman.

En el caso concreto de la corrección de imágenes AVHRR, aunque es extensible a otros sensores, la navegación de la imagen implica un proceso matemático complejo, que excede el carácter introductorio de esta obra. Para una referencia completa pueden consultarse otras referencias más específicas (Bachmann y Bendix, 1992; Bordes *et al.*, 1992; Emery *et al.*, 1989; Ho y Asem, 1986; Krasnopolsky y Breaker, 1994; Rosborough *et al.*, 1994). Baste aquí indicar que su principal escollo es localizar exactamente la posición geográfica del satélite, de tal forma que puedan relacionarse automáticamente sus coordenadas de imagen con las coordenadas cartográficas de interés. Es preciso conocer la altitud de la órbita, que puede variar a lo largo de la traza ya que no se emplean modelos circulares sino elípticos, su velocidad y meridiano de cruce con el Ecuador, así como la velocidad de barrido del sensor. A partir de esa información, los parámetros más sencillos de corregir son los derivados de errores sistemáticos en la adquisición, como son los siguientes:

1. *Inclinación de la imagen.* Tanto el NOAA como otros satélites de órbita polar adquieren las imágenes con un pequeño ángulo respecto al norte geográfico. Esto implica una inclinación del eje de la imagen hacia el noreste. Además, durante el tiempo de adquisición de la imagen, la Tierra se desplaza hacia el este, en una distancia variable con la latitud, la velocidad angular del satélite y el tamaño del área cubierta en la imagen. Estos problemas pueden obviarse de acuerdo a las siguientes fórmulas (Richards, 1993), pp. 48-54 (fig. 6.45).

$$\Delta x = \Delta x_e \cos \delta \qquad \{6.57\}$$

$$\Delta x_e = v_e \, T_s \qquad \{6.58\}$$

$$v_e = \omega_e \, r_e \cos \phi \qquad \{6.59\}$$

$$T_s = L / (r_e \, \omega_o) \qquad \{6.60\}$$

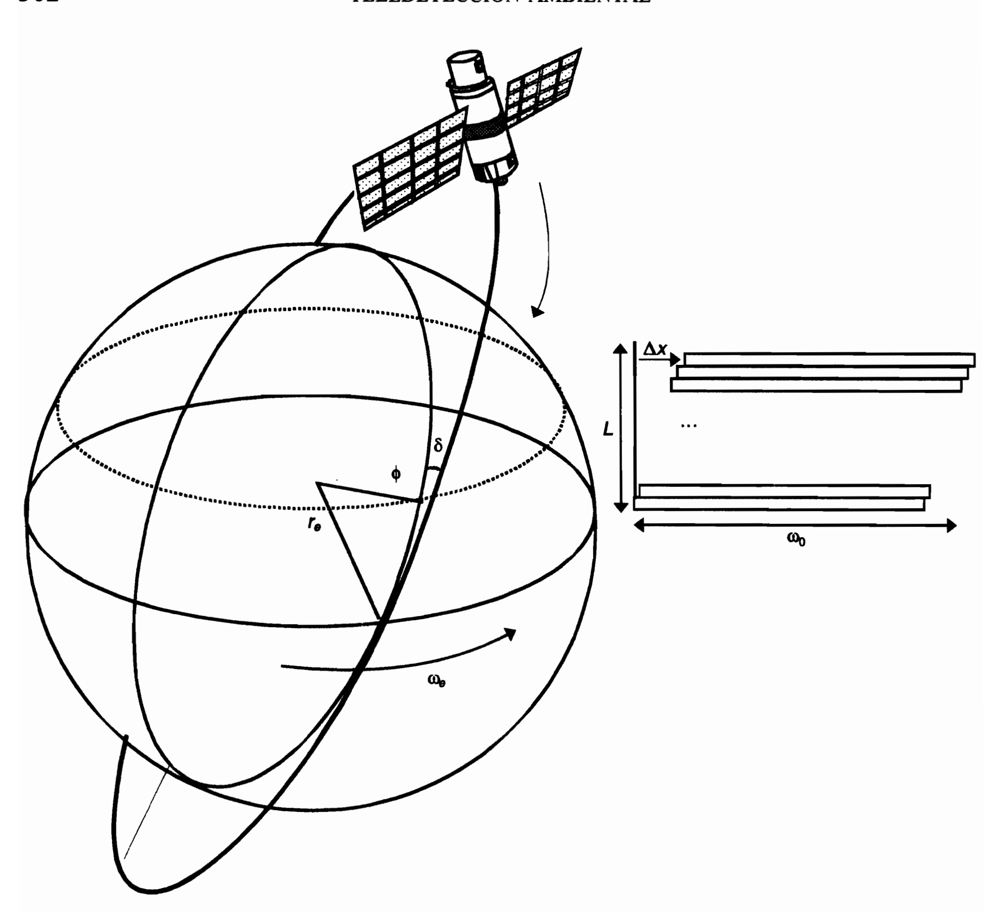


FIG. 6.45. *Errores geométricos causados por la rotación terrestre (adaptado de Richards, 1993).*

De la primera se deduce que el desplazamiento de la imagen en el eje x (Δx) es igual al desplazamiento debido al movimiento de la Tierra (Δx_e) multiplicado por el coseno del ángulo de inclinación de la órbita (δ). A su vez, de {6.58} calculamos ese desplazamiento de la Tierra (Δx_e) a partir de su velocidad angular (ν_e) y del tiempo de adquisición de la imagen (T_s). La velocidad angular puede calcularse a partir de la velocidad rotacional de la Tierra (ω_e= 72,72 µrad/s), del radio terrestre (re ≈ 6.378 km) y de la latitud de la imagen (ϕ). Por su parte, el tiempo de adquisición está en función del área cubierta (L) y de la velocidad angular del satélite (ω_o). En definitiva, basta saber la inclinación de la órbita del satélite, su velocidad angular y el área que abarcan sus imágenes para posicionarlas aproximadamente hacia el norte.

2. *Distorsión panorámica.* En cualquier sensor óptico las imágenes se adquieren desde un punto de observación, por lo que los parámetros de adquisición (sobre todo la distancia sensor-Tierra) sólo son exactos en la vertical del mismo (nadir). Entre otros efectos de esta observación panorámica, uno de los más agudos es la variación del tamaño del píxel desde el nadir hasta los extremos, pues aumenta la distancia entre el sensor y el punto observado. En el caso de imágenes de pequeño

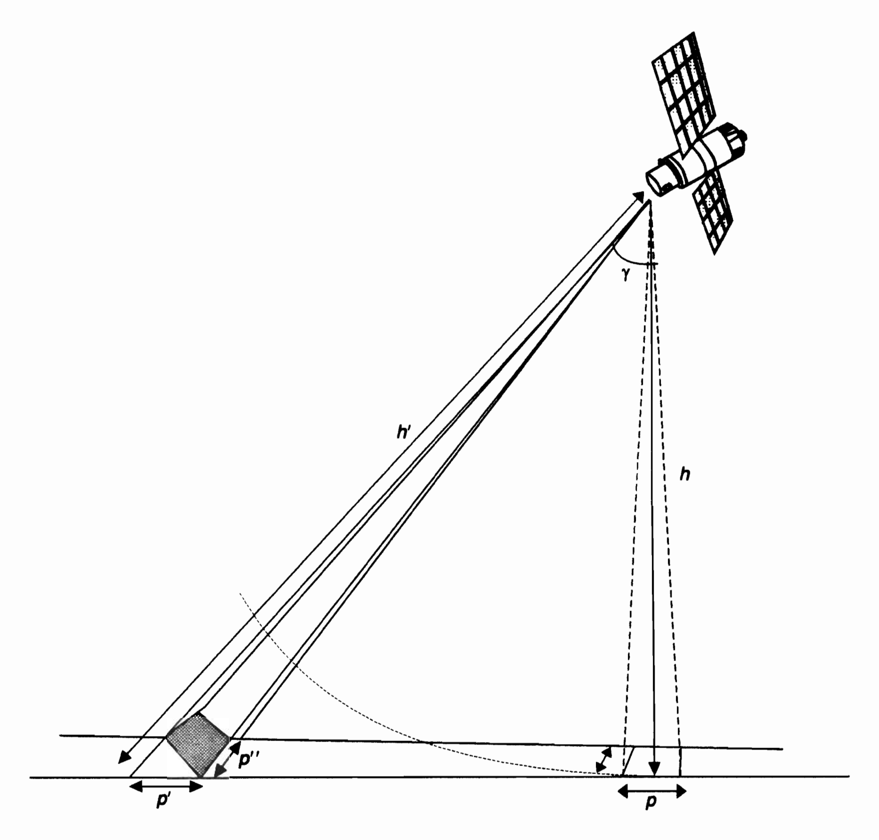


FIG. 6.46. *Efecto de la observación panorámica sobre la geometría de la imagen (adaptado de Richards, 1993).*

campo de visión (como el Landsat-TM, SPOT-HRV o IRS-1C) ese efecto es poco importante, pues adquieren imágenes casi verticales. No es así para las imágenes de los sensores globales, que cuentan con un gran ángulo de barrido, lo que implica errores considerables hacia los extremos del área observada (fig. 6.46) .

Una sencilla corrección de este efecto panorámico viene dada por las fórmulas siguientes:

$$p' = p / \cos^2 \gamma \qquad \{6.61\}$$

en la dirección y del píxel (latitud), y

$$p'' = p / \cos \gamma \qquad \{6.62\}$$

en la dirección x del píxel (longitud), siendo p el tamaño del píxel en el nadir y γ el ángulo de barrido (formado por la línea de observación y la vertical al sensor: fig. 6.46). En este esquema se asume que el campo de visión instantáneo (IFOV) es constante. Esta corrección permite ajustar el tamaño del píxel con la distancia al nadir, a lo largo de cada línea de barrido.

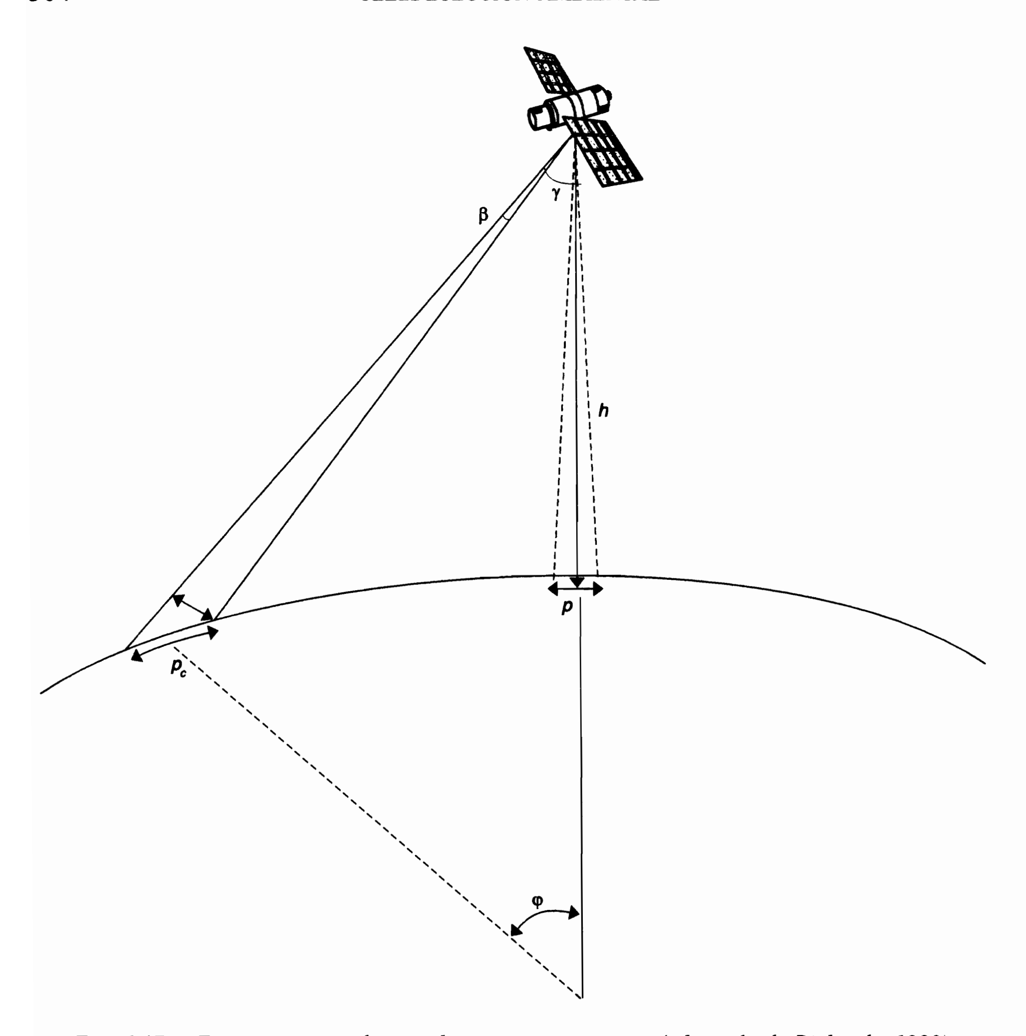


FIG. 6.47. *Errores provocados por la curvatura terrestre (adaptado de Richards, 1993).*

3. *Efecto de la curvatura terrestre.* Mientras en el caso de la fotografía aérea, el área observada permite asumir la Tierra como plana, en las imágenes de satélite la esfericidad terrestre no puede obviarse, especialmente en aquellos sensores que observan una superficie muy vasta, como es el caso del AVHRR. Para mitigar este efecto, puede abordarse la siguiente corrección (Richards, 1993) (fig. 6.47):

$$p_c = \frac{\beta(h + r_e(1 - \cos\varphi))}{\cos\gamma\cos(\gamma + \varphi)} \qquad \{6.63\}$$

donde p_c indica el tamaño del píxel corregido del efecto de curvatura, β es el ángulo de visión instantánea, h la altura del sensor, r_e el radio de la Tierra, γ el ángulo de barrido y φ el formado por el centro del píxel observado y el centro de la Tierra.



FIG. 6.48. *Efecto de la corrección orbital de imágenes (imágenes adquiridas por el AVHRR en julio de 1991).*

A partir de estas ecuaciones, conociendo la posición geográfica del satélite, puede navegarse la imagen, generando una malla de coordenadas *x*, y con los ND adquiridos por el sensor más aproximados a cada posición. Este proceso de interpolación es relativamente similar al que veremos para la corrección con puntos de control. El conjunto del proceso implica un volumen considerable de cálculo, ya que las ecuaciones de ajuste son bastante complejas. En ocasiones, los modelos orbitales se apoyan en la localización de algún punto de control terrestre, para mejorar la estimación de las condiciones de orientación del satélite *(attitude)*.

La figura 6.48 incluye una secuencia de imágenes AVHRR adquiridas en tres días consecutivos. A la izquierda aparecen las imágenes originales, mostrando los efectos de distorsión geométrica que estas imágenes incluyen. Los extremos aparecen severamente deformados, cambiando esa área según se desplaza el centro de la imagen hacia el oeste. A la derecha, aparece un sector próximo a la ciudad de Valencia, tras la corrección orbital, referenciada en proyección UTM. Como puede observarse, pese a la gran diferencia en la geometría de las imágenes originales la corrección consigue posicionar las imágenes de forma bastante similar entre ellas.

Esta solución será suficiente para aplicaciones globales, en donde se pretendan analizar grandes extensiones. Sin embargo para análisis multitemporales más detallados, no facilita habitualmente la precisión requerida. Como veremos en el capítulo de detección de cambios (7.3), un proceso previo imprescindible para determinar qué se ha modificado entre dos o más imágenes es que se refieran exactamente a la misma zona. Pequeños desplazamientos entre los píxeles de las imágenes que se comparan estarían mostrando cambios ficticios. La importancia de este factor puede llegar a ser muy considerable (Roy, 2000; Townshend *et al.*, 1992), por lo que resultará imprescindible mejorar esa corrección con otros ajustes más detallados cuan-

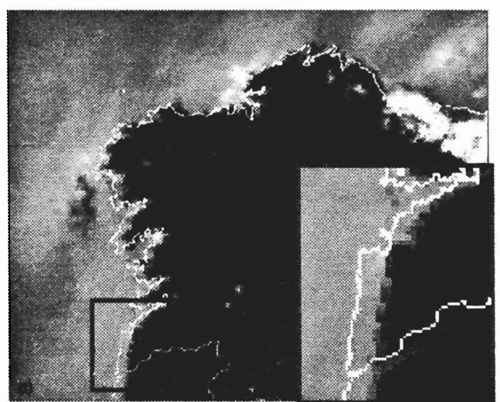
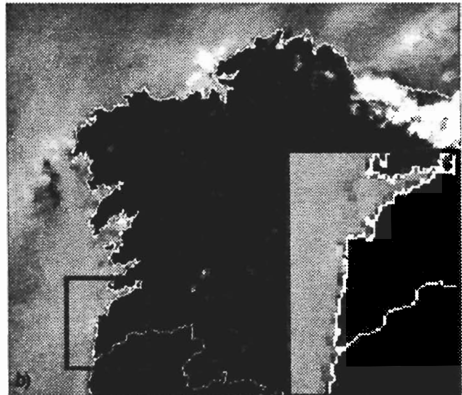



FIG. 6.49. *Mejora en los ajustes orbitales mediante correcciones con puntos de control:* a) *ajuste orbital;* b) *añadiendo puntos de control. (Cortesía M. Pilar Martín.)*

do se pretendan analizar superficies que ocupen pocos píxeles (Martín, 1998). El efecto es especialmente evidente en zonas costeras (fig. 6.49).

6.3.3. *Corrección a partir de puntos de control*

La segunda alternativa de corrección es más inductiva. Asume que no se conoce el origen de los errores, pero que éstos pueden modelarse a partir de ajustar unas ecuaciones empíricas a un conjunto de puntos, de los que se conocen tanto las coordenadas de la imagen a corregir como las del mapa o imagen de referencia. En ambos casos, la corrección se realiza en tres fases (fig. 6.50): 1) localización de puntos comunes a la imagen y al mapa (o a otra imagen de referencia), 2) cálculo de las funciones de transformación entre las coordenadas de la imagen objetivo y las de referencia, y 3) transferencia de los ND originales a la nueva posición, definida por la función de ajuste.

6.3.3.1. Establecimiento de puntos de control

Para calcular cualquier función entre dos o más variables, es necesario contar previamente con una serie de observaciones comunes a todas ellas. De la misma forma, las funciones que permiten transformar coordenadas entre la imagen y el mapa precisan localizar una serie de puntos comunes a ambos sistemas de referencia. Estos sitios se conocen como puntos de control. A partir de sus coordenadas imagen y mapa, se calculan las funciones de ajuste, de forma similar a como se obtienen en otras regresiones multivariables. En consecuencia, la calidad del ajuste dependerá de la precisión con que se localicen esos puntos, y de cómo definan realmente los errores geométricos de la imagen. Una inexacta localización de esos puntos, tanto en la imagen como en el mapa, o una distribución muy sectorizada, implicará una estimación inadecuada y, por tanto, una corrección geométrica errónea. En definitiva, el establecimiento de puntos de control resulta la fase más crucial del proceso de corrección y la que demanda mayor dedicación humana.

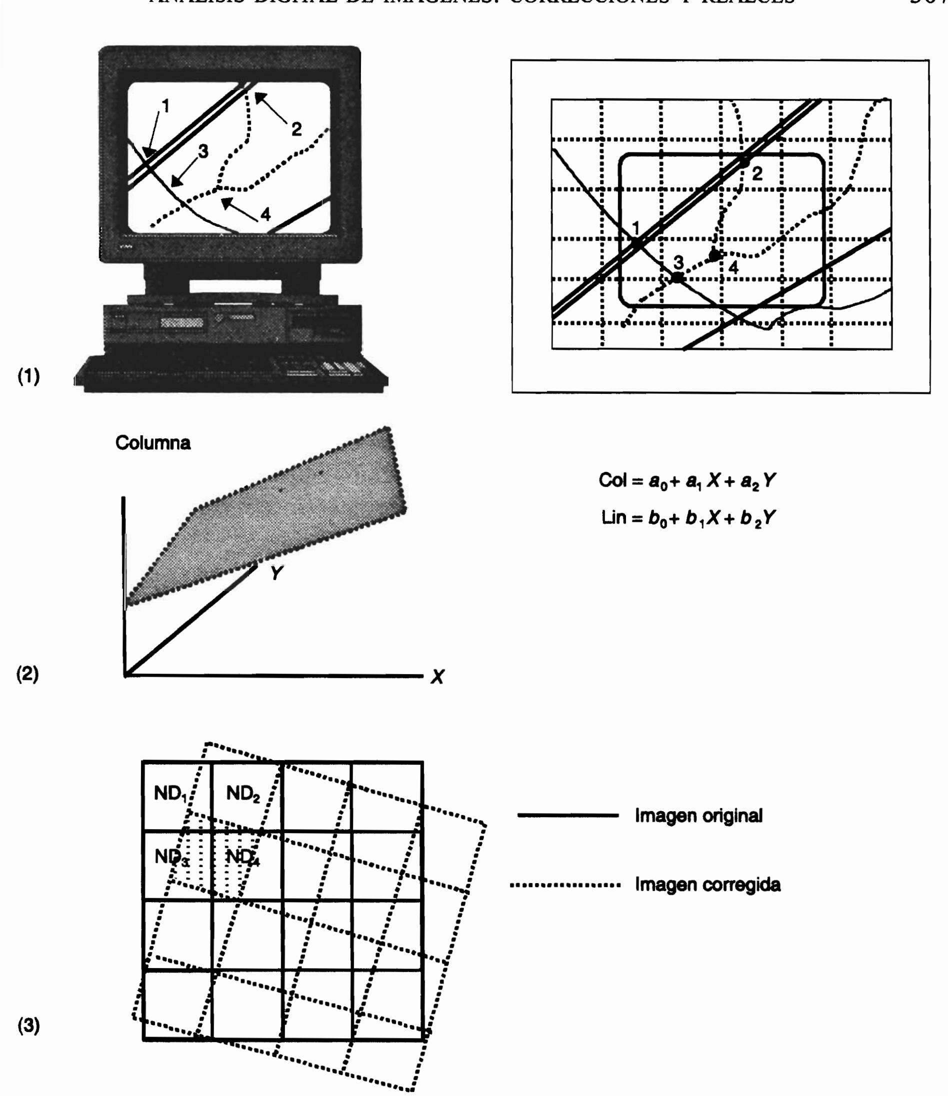


FIG. 6.50. *Fases de la corrección con puntos de control: 1) selección; 2) ecuaciones de ajuste, 3) generación de la imagen corregida.*

Para que el ajuste entre imagen y mapa sea correcto, se requiere atender a tres aspectos en la selección de los puntos de control: número, localización, y distribución.

El número idóneo de puntos de control depende del tamaño y la complejidad geométrica de la imagen. Si se trata de zonas planas, adquiridas por un sensor de estrecho campo de visión, la transformación imagen-mapa puede basarse en ecuaciones lineales simples. Por el contrario, si se trata de un terreno rugoso o el sensor varía notablemente las condiciones de observación, será preciso aplicar funciones de transformación más complejas, con polinomios de segundo o tercer grado. Lógicamente, cuanto mayor sea el grado de la ecuación de ajuste, se precisará también un mayor número de puntos de control. Matemáticamente sólo son necesarios 3 puntos

para una función de ajuste de primer grado, 6 para una de segundo grado y 10 para una de 3.er grado. Ahora bien, conviene superar con creces ese listón mínimo para garantizar una buena conformidad entre imagen y mapa. Bernstein (1978) aconsejaba seleccionar entre 14 y 20 puntos para corregir una imagen MSS, mientras el *National Remote Sensing Center* inglés utilizaba de 100 a 120 puntos para hacer lo propio con una imagen TM (Davison, 1984). Para una zona pequeña (512 × 512 píxeles, por ejemplo), 10 o 12 puntos y una transformación de primer grado serán normalmente suficientes. En caso de que el contraste topográfico sea importante, convendrá seleccionar un mayor número de puntos, y acudir a polinomios de transformación más complejos.

En cuanto a la localización, se recomienda que sean puntos claramente identificables en la imagen y en el mapa, preferiblemente rasgos humanos del paisaje no sujetos a dinamismo temporal: cruces de carreteras, caminos, vías de ferrocarril, etc. Siempre que sea posible, no conviene señalar puntos en la línea de costa, pues el efecto de la marea puede modificar la localización exacta de un accidente geográfico. La misma idea puede aplicarse a los cursos de agua o embalses, que sufren alteraciones estacionales, en ocasiones de gran importancia. Algún elemento destacado de la vegetación podría utilizarse como punto de control, siempre que se disponga de la cartografía temática apropiada y no se hayan producido cambios entre la fecha de la imagen y la del mapa. En caso de que se pretenda el registro de dos imágenes, la búsqueda de puntos comunes resulta más sencilla, ya que hay rasgos visualizables en una imagen que no se recogen en la cartografía básica, como es el caso de manchas características de vegetación o ciertas parcelas agrícolas. La mayor parte de los programas de interpretación digital permiten visualizar las dos imágenes a corregir simultáneamente, lo que facilita mucho la selección de los puntos de control.

Respecto a su distribución, conviene que estos puntos se sitúen uniformemente sobre todo el territorio abarcado en la imagen. Esto evitará errores debidos a una ponderación excesiva de algún sector del área de estudio, en donde el ajuste será bueno a expensas de otros sectores de la imagen. Esto es especialmente importante cuando la zona presente contrastes topográficos y se utilicen ecuaciones de segundo o tercer grado. Aunque el efecto de desplazamiento del relieve es menor que en el caso de la fotografía aérea (debido a la altura de la órbita), también en las imágenes de satélite existe un efecto de desplazamiento que puede causar serios problemas en su ajuste cartográfico. Para intentar paliarlos, cuando no se disponga de un buen modelo digital de elevaciones, puede ser recomendable tomar puntos de control sobre áreas de distinta altitud, siempre que éstas resulten bien identificables en la imagen (Itten y Meyer, 1993; Novak, 1992; Palà y Pons, 1995).

Nuestra propia experiencia indica que la selección de puntos de control es una tarea bastante laboriosa. En caso de un registro entre dos imágenes, el proceso se simplifica, puesto que es más sencillo identificar puntos comunes entre dos imágenes que entre imagen y mapa. En el primer caso, pueden utilizarse cruces de caminos y rasgos destacados de la vegetación, de difícil o imposible localización en un mapa. Además, en el caso de corregir distintas imágenes de la misma zona para un análisis multitemporal, puede automatizarse el proceso de búsqueda de puntos comunes, a partir de señalar en una sola, de modo muy preciso, esos puntos, situando en las otras

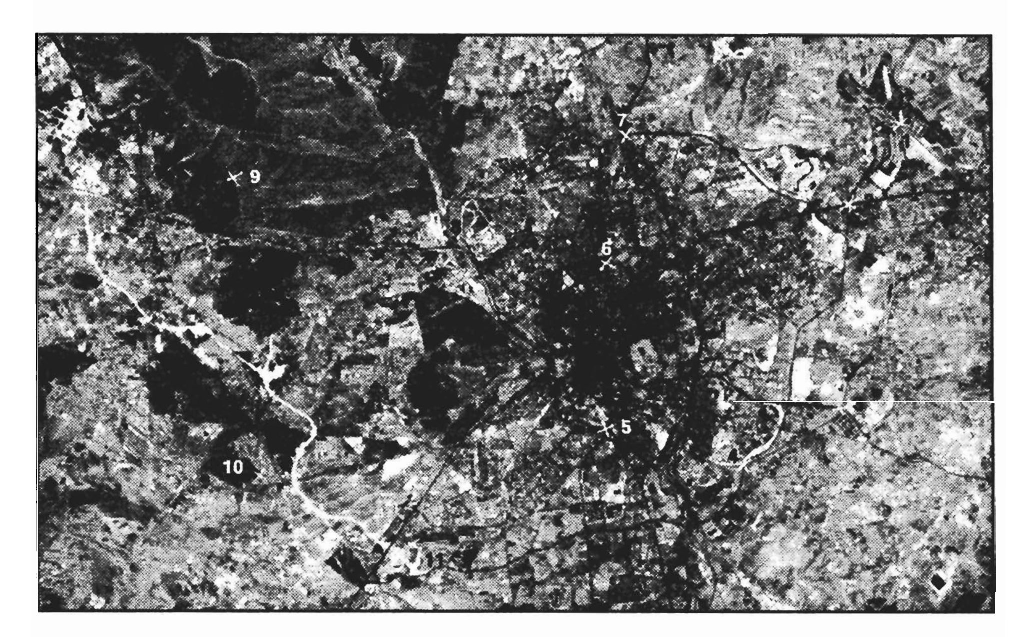


FIG. 6.51. *Puntos de control utilizados para la corrección de la imagen de Madrid92.*

unas ventanas de búsqueda, en torno a cada punto de control (Diez de Arribas y Nicolás, 2001; Ortí *et al.*, 1979).

La figura 6.51 recoge la localización de los puntos de control seleccionados para una imagen de la ciudad de Madrid. Al tratarse de una zona urbana, es relativamente sencillo encontrar puntos de control para esta imagen, ya que existen múltiples rasgos humanos claramente identificables sobre la imagen y el mapa. Para simplificar la figura, hemos señalado once puntos de control. La tabla 6.6 incluye las coordenadas columna y línea de la imagen, y *x* e *y* del mapa para esos puntos. La cartografía base se corresponde a una hoja 1:25.000 del Instituto Geográfico Nacional, realizada en proyección U.T.M.

TABLA 6.6. *Coordenadas de los puntos de control utilizados para corregir la imagen Madrid92*

Número	*x-mapa*	*y-mapa*	*Columna*	*Fila*
1	452.450	4.480.500	992	102
2	450.300	4.478.100	936	195
3	448.500	4.471.100	923	431
4	444.750	4.469.800	810	498
5	440.300	4.472.100	651	453
6	441.500	4.477.750	653	264
7	443.050	4.481.950	677	117
8	436.125	4.479.900	464	230
9	429.550	4.483.050	227	165
10	428.150	4.472.750	253	512
11	432.900	4.469.450	428	591

6.3.3.2. Cálculo de las funciones de transformación

Como se comentó más arriba, la corrección digital de la geometría de una imagen se realiza estableciendo unas funciones, que pongan en relación las coordenadas de la imagen con las del mapa. De esta forma, a partir de las coordenadas X, Y del mapa puede estimarse que columna y línea de la imagen corresponde a esa localización. Esquemáticamente esta transformación puede expresarse como (Mather, 1998):

$$\hat{s} = \sum_{j=0,\,m} \sum_{k=0,\,m-j} a_{j,k}\; X^j Y^k \qquad \{6.64\}$$

donde indica la coordenada estimada de la imagen corregida, que se obtiene a partir de las coordenadas del mapa X e Y. El superíndice m indica el grado del polinomio de ajuste. El caso más simple sería el de una ecuación lineal, en donde:

$$\begin{aligned} \widehat{ci} &= a_0 + a_1\, X_i + a_2\, Y_i \\ \widehat{li} &= b_0 + b_1\, X_i + b_2\, Y_i \end{aligned} \qquad \{6.65\}$$

donde y son las coordenadas estimadas columna y línea, respectivamente, para unas coordenadas determinadas del mapa, X_i e Y_i. En esencia, se trata de una regresión lineal múltiple, donde a_0, a_1, a_2, b_0, b_1, y b_2 son los coeficientes de regresión; X_i e Y_i, las variables independientes, y c_i, l_i las dependientes. También podrían formularse otras dos ecuaciones similares, en donde las variables estimadas fueran las coordenadas X, Y del mapa, a partir de las coordenadas c, l de la imagen. En definitiva, la conversión puede realizarse en un doble sentido: desde las coordenadas del mapa hasta la imagen y viceversa.

Al igual que en la regresión convencional, estas funciones pueden definirse gráficamente por un plano, que expresa la relación entre las coordenadas de las variables independientes (eje X e Y), y la variable dependiente (eje c o l). Desde el punto de vista práctico, conviene considerar que basta una función lineal para abordar un amplio conjunto de transformaciones de la imagen, como cambiar su escala y origen, inclinarla, modificar la relación entre sus ejes y rotarla (fig. 6.52). Estas alteraciones serán suficientes para corregir imágenes pequeñas, siempre que no se presenten contrastes altimétricos importantes. En caso de precisar una modificación más rigurosa, puede acudirse a funciones de segundo o tercer grado, en donde se abordan alteraciones geométricas no lineales. En otras palabras, la función no se define por un plano, con ejes lineales, sino por una superficie, con ejes curvilíneos. Por razones de mayor sencillez en la exposición, nos centraremos en las funciones de primer grado, si bien pueden aplicarse los comentarios al caso de polinomios más complejos.

Los coeficientes de las funciones de transformación se calculan habitualmente a partir de aplicar un ajuste por mínimos cuadrados, con operaciones de cálculo idénticas a las que requiere una regresión múltiple convencional (Estébanez y Bradshaw, 1978; Snedecor y Cochran, 1980).

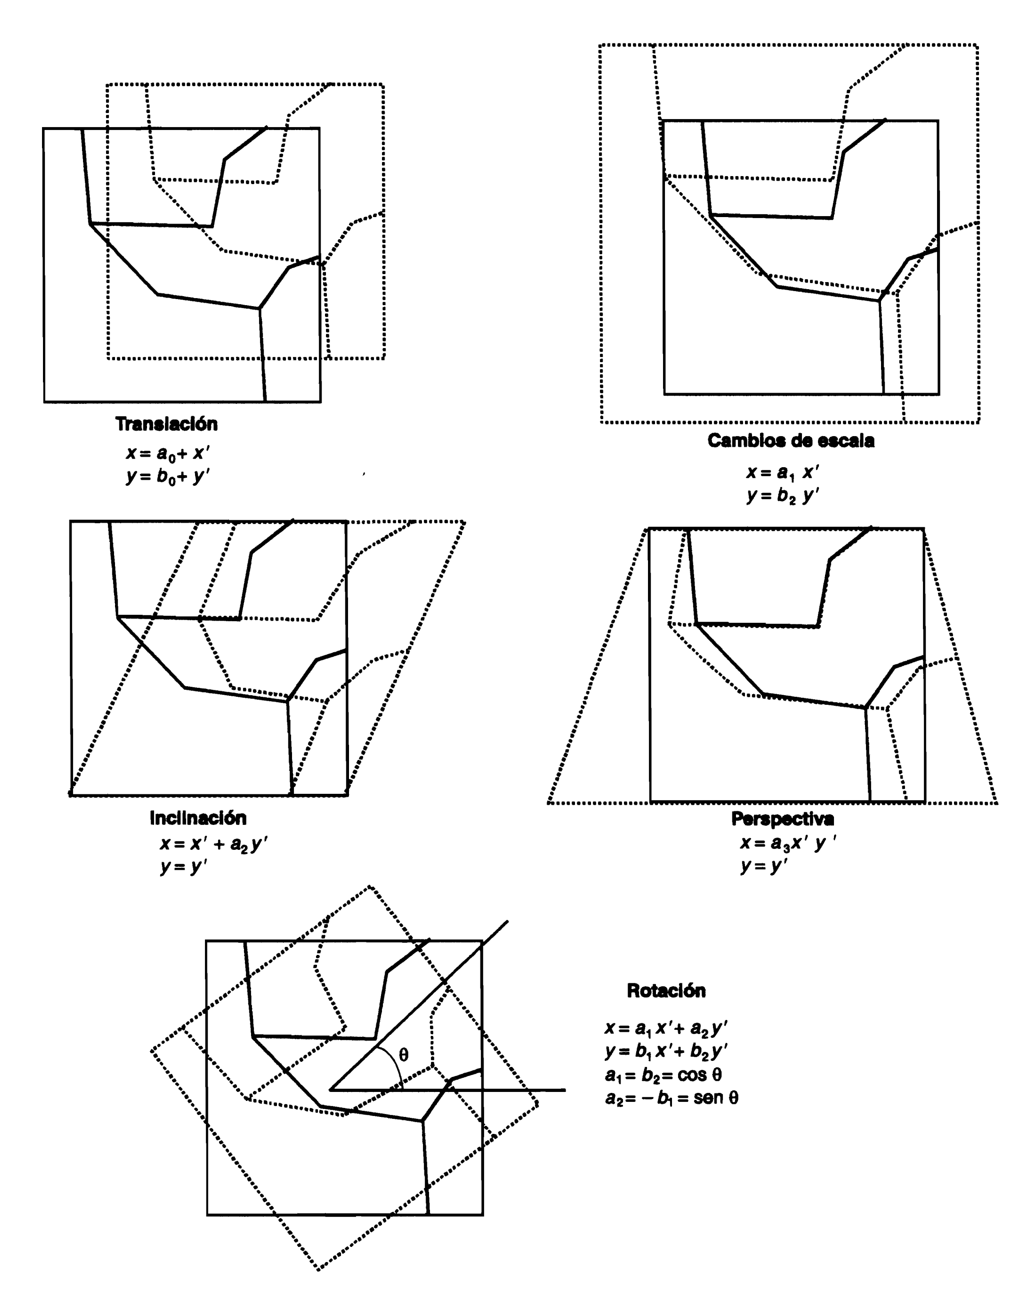


FIG. 6.52. *Ejemplos de funciones de transformación geométrica con el efecto que provocan (adaptado de Schowengerdt, 1983).*

La bondad del grado de ajuste conseguido se mide por la importancia de los residuales. Como es bien sabido, el residual de la regresión es la diferencia entre el valor estimado y el observado, para cada uno de los puntos muestrales empleados en el proceso. Cuanto mayor sea ese valor, el ajuste entre las variables independien-

te y dependiente es menor. En nuestro caso, la calidad de la corrección geométrica puede valorarse comparando, para cada punto de control, las coordenadas estimadas por la regresión con las reales. El promedio de los residuales habitualmente se conoce como error medio cuadrático (*Root Mean Squared Error*, RMSE). El RMSE se calcula como la raíz cuadrada de las desviaciones entre los valores observados y los estimados por la regresión, tanto para filas como para columnas. En nuestro caso:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1,\,n}\left((\hat{c}_i - c_i)^2 + (\hat{l}_i - l_i)^2\right)}{n-1}} \qquad \{6.66\}$$

También puede calcularse el RMSE para cada punto, simplemente como la raíz de los residuales al cuadrado para ese punto. Ese valor no es más que la distancia entre sus coordenadas reales y las estimadas por la regresión (fig. 6.53). En consecuencia, podemos también utilizar el término error longitudinal (EL) para referirnos al RMSE de un punto concreto:

$$\text{EL} = \sqrt{(\hat{c}_i - c_i)^2 + (\hat{l}_i - l_i)^2} \qquad \{6.67\}$$

Empleando este término puede resolverse una frecuente confusión que considera al RMSE como sólo aplicable al conjunto de los puntos (por el término, error medio), y no a cada punto individualmente. Además, es más acorde con la variable que estamos estimando (posición) y con el tipo de errores que cometemos (distancia al punto observado).

La calidad general del ajuste se evalúa a través del RMSE o del valor de los EL para cada punto. Si el promedio supera un cierto valor previamente indicado (habitualmente igual o inferior a 1 píxel) será necesario aplicar alguna de las siguientes soluciones:

1. Verificar las coordenadas de los puntos introducidos, revisando que tanto las coordenadas de la imagen como las del mapa sean precisas. En esta fase puede ser conveniente anotar el grado de confianza que nos merece ese punto, según la seguridad que tengamos en su correcta localización.
2. Si una vez verificadas las coordenadas se mantiene un alto RMSE puede ser conveniente eliminar algún punto con mayor tasa de error, siempre que se trate de los catalogados como de dudosa fiabilidad, o se sitúe sobre un área próxima a otros puntos incluidos en la ecuación, lo que permitirá mantener ese sector en el ajuste final. Eliminar un punto de un sector poco representado puede suponer una reducción artificiosa del error, que luego se manifieste en sectores de la imagen que estarán mal referenciados.
3. También podemos optar por incrementar el orden del polinomio, en caso de que las deformaciones de la imagen sean muy severas, por ejemplo en terrenos quebrados. Esta solución debe tomarse con cautela, especialmente cuando el número de puntos sea pequeño, ya que se puede obtener un «sobreajuste» a esas zonas,

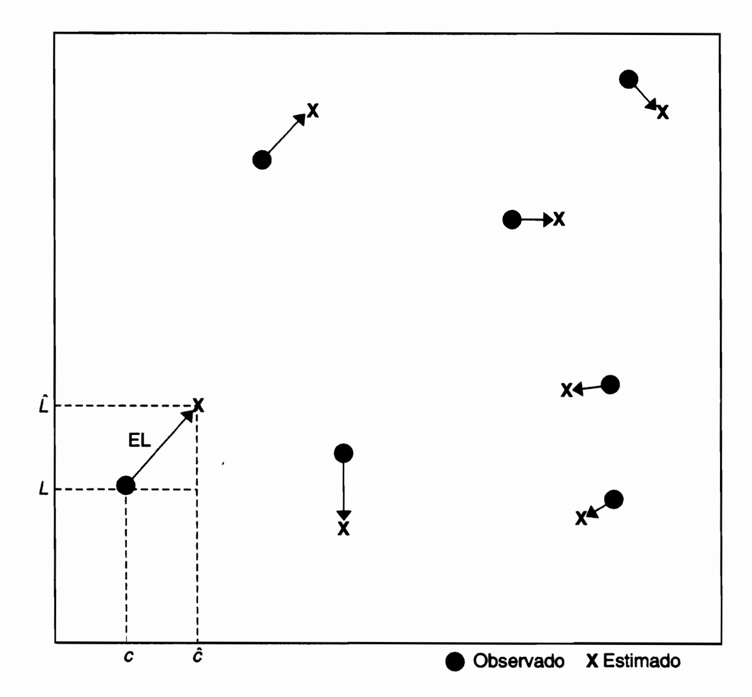


FIG. 6.53. *El error longitudinal indica la distancia entre la posición real de un punto de control y la estimada por la ecuación de ajuste.*

introduciendo errores notables en otras poco representadas, aun cuando los residuales sean bajos (Richards, 1993), pp. 67-70).

Por ésta y otras razones, para verificar adecuadamente la corrección geométrica es necesario introducir puntos de verificación, que no se hayan utilizado en el cálculo de la ecuación de ajuste, y permitan estimar el RMSE real obtenido en el proceso. Esto permitiría evitar el sesgo que una incorrecta distribución de puntos pudiera presentar, ya que se evalúa el error no sobre los puntos muestrales, sino sobre otros adquiridos de modo independiente al ajuste.

Para la corrección de la imagen de Madrid, teniendo en cuenta la ausencia de relieves importantes en la escena, se optó por elegir una ecuación de ajuste de primer grado, con un RMSE no superior a 1 píxel (30 m). A partir de los 11 puntos de control seleccionados previamente (tabla 6.6), se obtuvieron unas funciones iniciales de transformación. El estudio de los residuales y los EL de cada punto nos permitió observar errores excesivos en la localización de algunos de ellos (tabla 6.7), ofreciéndose un RMSE excesivamente elevado (2,13 píxeles). Tras verificar las coordenadas, se optó también por eliminar dos puntos que parecían algo más conflictivos. Con los nueve puntos resultantes se obtuvieron las siguientes ecuaciones.

$$\widehat{c} = 15.177,79 + 0,032452\ X - 0,006443\ Y \qquad \{6.68\}$$

$$\widehat{l} = 147.365,5 - 0,006590\ X - 0,032202\ Y \qquad \{6.69\}$$

TABLA 6.7. *Residuales de la primera corrección (todos ellos en píxeles)*

Número	*Columna*	*Columna estimada*	*Residual columna*	*Fila*	*Fila estimada*	*Residual fila*	*EL*
1	992	990,65	1,35	102	102,16	–0,16	1,36
2	936	936,54	–0,54	195	194,15	0,85	1,00
3	923	924,16	–1,16	431	433,48	–2,48	2,74
4	810	810,75	–0,75	498	500,08	–2,08	2,21
5	651	650,81	0,19	456	454,14	1,86	1,87
6	652	652,57	–0,57	264	262,61	1,39	1,50
7	677	675,29	1,71	116	115,97	0,03	1,71
8	463	463,53	–0,50	230	227,55	2,45	2,51
9	227	228,86	–1,86	165	167,75	–2,75	3,32
10	253	251,27	1,73	510	511,80	–1,80	2,50
11	428	427,56	0,44	591	588,32	2,68	2,72

que ofrecieron un ajuste bastante adecuado, con un RMSE de 0,76. Esto supone un error estimado en las distancias de 22,8 m, aceptable para nuestros propósitos. La tabla 6.8 recoge los residuales finales.

6.3.3.3. Transferencia de los ND originales a la posición corregida

Las funciones antes analizadas permiten traducir coordenadas del mapa a la imagen. Ahora bien, si pretende crearse una imagen que se corresponda adecuadamente con esas coordenadas, resulta necesario trasvasar, de alguna forma, los ND de la imagen original a esa nueva posición. Las funciones de ajuste permiten calcular la posición correcta de cada píxel, pero no originan una nueva imagen, puesto que suponen sólo un trasvase de coordenadas y no de ND. Dicho de otro modo, con estas funciones de transformación puede crearse una nueva matriz, correctamente posicionada, pero vacía. El «llenado» de esta matriz es, precisamente, el objetivo de la última fase de la corrección geométrica.

TABLA 6.8. *Residuales de la segunda corrección*

Número	*Columna*	*Columna estimada*	*Residual columna*	*Fila*	*Fila estimada*	*Residual fila*	*EL*
1	992	990,96	1,04	102	102,60	–0,60	1,20
2	936	936,65	–0,65	195	194,05	0,95	1,15
3	923	923,34	–0,34	431	431,33	–0,33	0,47
4	810	810,02	–0,02	498	497,90	0,10	0,10
5	651	650,79	0,21	453	453,16	–0,16	0,27
6	653	653,33	–0,33	264	263,31	0,69	0,76
7	677	676,56	0,44	117	117,85	–0,85	0,95
8	464	465,04	–1,04	230	229,50	0,50	1,16
10	253	252,31	0,69	512	512,30	–0,30	0,75
11	428	427,56	0,44	591	588,32	2,68	2,72

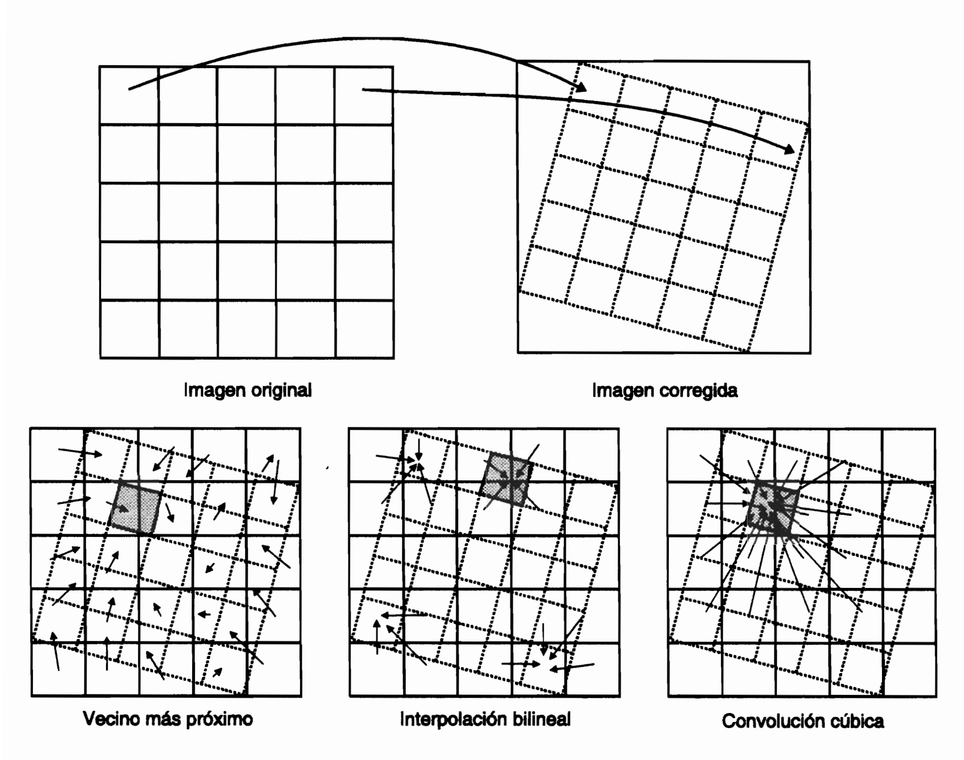


FIG. 6.54. *Procedimiento para transferir los* ND *originales a la posición corregida.*

El problema resulta más complejo de lo que pudiera pensarse a primera vista. Idealmente, cada píxel de la imagen corregida debería corresponderse a un sólo píxel en la original. Lo normal es que no sea así, sino que el píxel de la nueva imagen se sitúe entre varios de la original (fig. 6.54), ya que este proceso supone una alteración considerable de la geometría original de la escena. Por otra parte, puede variarse también el tamaño del píxel en la imagen corregida, haciendo aún más complejo encontrar el ND que mejor exprese el valor radiométrico detectado por el sensor para esa posición.

El trasvase de ND a las coordenadas cartográficas de interés puede abordarse por tres métodos: 1) vecino más próximo, 2) interpolación bilineal, y 3) convolución cúbica. Simplificando las cosas pueden resumirse en dos, según almacenen un ND de la imagen original o lo obtengan mediante una interpolación de varios ND originales.

El método del vecino más próximo *(nearest neighbour)*, se basa en situar en cada celdilla de la imagen corregida el ND del píxel más cercano en la imagen original. Ésta es la solución más rápida y la que supone menor transformación de los ND originales. Su principal inconveniente radica en la distorsión que introduce en rasgos lineales de la imagen (fallas, carreteras o caminos), que pueden aparecer en la corregida como líneas quebradas) (figs. 6.55 y 6.56).

La interpolación bilineal *(bilinear interpolation)*, supone promediar el ND de los cuatro píxeles más cercanos en la original. Este promedio se pondera según la

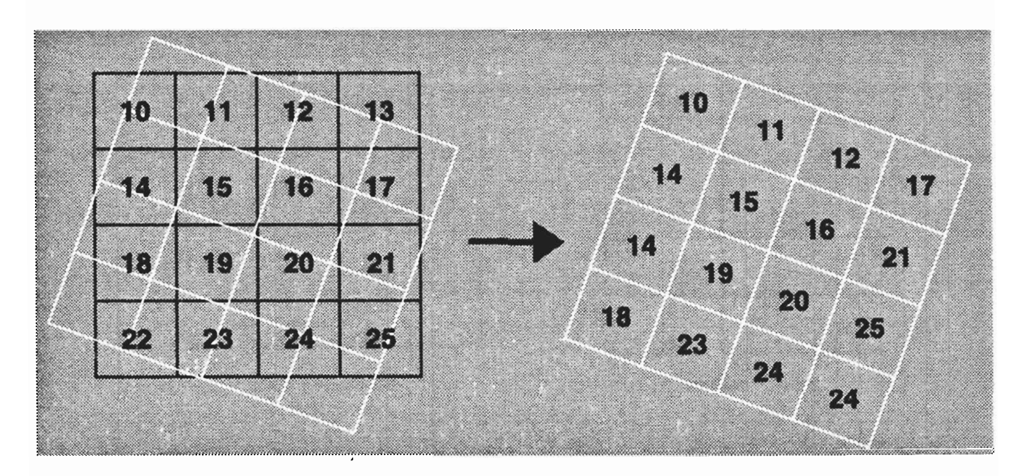


FIG. 6.55. *En el criterio del vecino más próximo pueden aparecer líneas quebradas, al rotarse los ejes de la imagen con el proceso de georreferenciación.*

FIG. 6.56. *Criterios de interpolación para la banda 4 de Torre100:* a) *original,* b) *vecino más próximo;* c) *interpolación bilineal;* d) *convolución cúbica.*

distancia del píxel original al corregido: tienen una mayor influencia aquellos píxeles más cercanos en la imagen inicial. Reduce el efecto de distorsión en rasgos lineales, pero tiende a difuminar un tanto los contrastes espaciales de la imagen original.

Por último, la convolución cúbica *(cubic convolution)* considera los ND de los 16 píxeles más próximos. El efecto visual es más correcto, pero supone un volumen de cálculo mucho más elevado.

La elección entre uno de los tres métodos depende de la finalidad del proceso y de los recursos informáticos disponibles. Si pretende corregirse una imagen clasificada, el método del vecino más próximo es la elección obligada, pues es el único que preserva los valores originales al no introducir promedios (que, por otra parte, no tendrían sentido en una clasificación temática). También ése sería el algoritmo más adecuado cuando se pretenda preservar lo más posible la radiometría original de la imaen. Caso de que la corrección geométrica se dirija principalmente a generar ortoimágenes para el análisis visual, convendrá optar por algoritmos de interpolación más elaborados, concretamente por el de convolución cúbica.

El efecto causado por estos tres métodos de trasvasar los ND a la imagen corregida se observa en la figura 6.56, correspondiente a la banda 4 de la imagen Torre100. Resulta evidente la deformación introducida por el vecino más próximo en el embalse de Santillana y en la carretera que une Colmenar Viejo y Soto del Real. Como puede observarse, las diferencias visuales entre la interpolación bilineal o cúbica son apenas perceptibles.

Para ilustrar con un ejemplo concreto la operación que realizan estos métodos de trasvase de ND, podemos comentar el proceso que se seguiría para obtener los ND de una imagen por el vecino más próximo y por interpolación bilineal. El ejemplo está tomado de la imagen de Madrid, para la que antes hemos indicado las ecuaciones de ajuste {6.68 y 6.69}.

En primer lugar, el intérprete tiene que definir el área sobre la que se va a aplicar el proceso. Para ello, necesita introducir al ordenador o bien las coordenadas UTM (X, Y)[1] de los vértices y el tamaño del píxel en X, Y, o bien las coordenadas de los vértices y el tamaño de la imagen en columnas y líneas. En el primer caso, se calcula el tamaño de la imagen dividiendo la diferencia de coordenadas entre el tamaño del píxel, y en el segundo se obtiene el tamaño del píxel dividiendo la diferencia de coordenadas entre el número de filas y columnas. Habitualmente se emplea la primera opción. En nuestro ejemplo se indicaron las siguientes coordenadas de los vértices NW (434.000, 4.480.000) y SE (449.000, 4.470.000), y como tamaño del píxel de salida 50 × 50 m.

Con estos datos, el programa opera de la forma siguiente:

1. Estima las coordenadas, en columnas y líneas, de los vértices de la imagen corregida, a partir de las ecuaciones de ajuste antes obtenidas {6.68 y 6.69}. Suele comenzarse por el vértice NW, puesto que resulta el origen de la nueva imagen, usando las funciones ajustadas previamente:

1. Para evitar malinterpretaciones, cuando indicamos las coordenadas UTM de un determinado píxel nos referimos a las coordenadas de su punto central.

$$\hat{c} = 15.177,79 + 0,032452 \times 434.000 - 0,006443 \times 4.480.000 = 397,38$$

$$\hat{l} = 147.365,50 - 0,006590 \times 434.000 - 0,032202 \times 4.480.000 = 240,48$$

2. La columna y línea estimada por el ajuste sirve para extraer el ND que vamos a situar en la posición 434.000 y 4.480.000. Si utilizamos el criterio del vecino más próximo, ese ND correspondería al del píxel situado en la columna 397 y línea 240 de la imagen original (los enteros más cercanos a los valores estimados por las ecuaciones). En caso de que utilizáramos la interpolación bilineal, el ND se obtendría por un producto ponderado de los cuatro más cercanos, de acuerdo a la siguiente fórmula:

$$ND_{sal} = \frac{\sum_{i=1,4} (ND_i / D_i^2)}{\sum_{i=1,4} (1 / D_i^2)} \qquad \{6.70\}$$

donde D_i indica la distancia entre el píxel i y el que pretende interpolarse. En nuestro ejemplo, el ND asignado a la posición 434.000 y 4.480.000 sería un promedio ponderado de los ND correspondientes a los píxeles 397-240, 397-241, 398-240 y 398-241. La distancia D se calcularía a partir de:

$$D = \sqrt{\Delta x^2 + \Delta y^2} \qquad \{6.71\}$$

donde ΔX y ΔY son las diferencias entre el valor estimado y el original en columna y línea, respectivamente. Por ejemplo, para el píxel situado en las coordenadas 397-240, $\Delta X = 0,38$ y $\Delta Y = 0,48$, luego $D = 0,612$. En consecuencia, ese píxel tendría más peso en el cálculo que el situado en 398-241, que contaría con una distancia de $D = 0,80$.

3. El resto de los ND de la imagen se obtienen de forma similar al indicado. Conociendo las coordenadas UTM del vértice NW de la zona y el tamaño del píxel, pueden irse calculando las coordenadas UTM del área que pretende «llenarse» con ND de la imagen original. Basta añadir a la coordenada X del vértice NW los 50 m de separación entre píxeles para obtener la siguiente coordenada X. En el caso de la coordenada Y, en lugar de sumar hay que restar el tamaño del píxel para obtener la siguiente fila de la imagen corregida, ya que las coordenadas en Y decrecen de norte a sur. Una vez calculadas las coordenadas UTM se introducen en las ecuaciones arriba indicadas, obteniendo la columna y fila estimada para tales coordenadas. A partir de esos valores estimados puede obtenerse el ND correspondiente a esas coordenadas. Por ejemplo, el píxel situado en la columna 220 y línea 165 de la imagen de salida, tendrá las siguientes coordenadas UTM:

$$X(220,165) = 434.000 + 220 \times 50 = 445.000$$

$$Y(220,165) = 4.480.000 - 165 \times 50 = 4.471.750$$

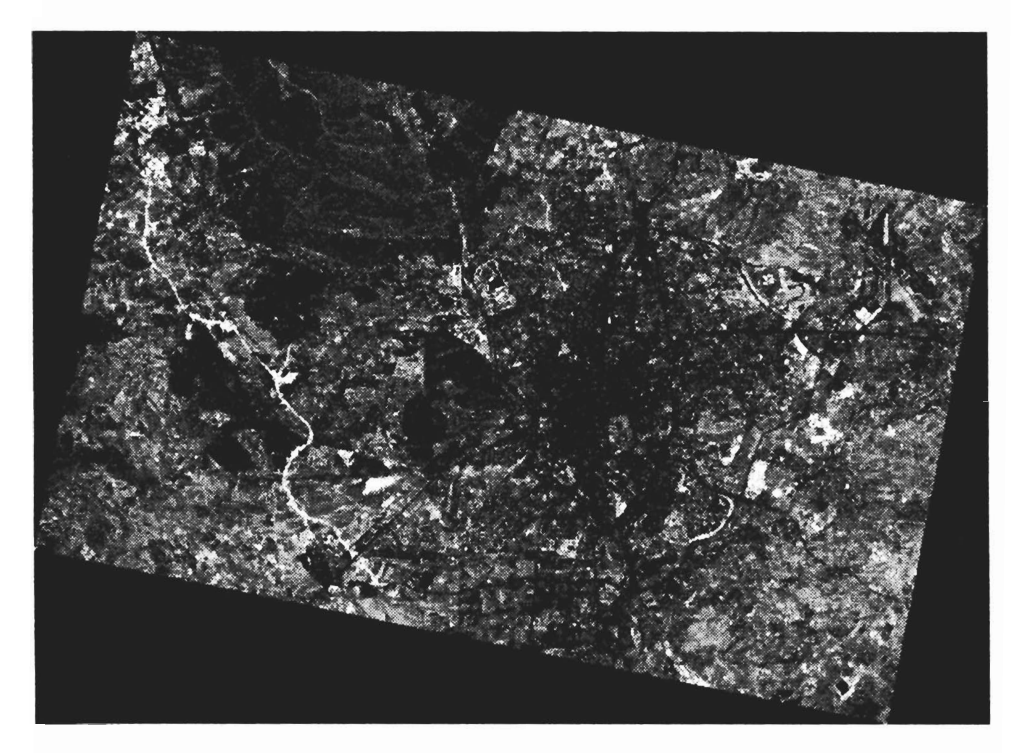


FIG. 6.57. *Banda 4 de la imagen Madrid92 georreferenciada a coordenadas UTM.*

A partir de esas coordenadas estimamos la localización en columna y línea de la imagen original usando {6.68 y 6.69}, lo que ofrece un valor estimado de columna y línea de 807,44 y 433,66, respectivamente. De ahí deducimos que el ND del píxel 220-165 en la imagen corregida, con coordenadas UTM 445.000 y 4.471.750 tendrá asignado el ND del píxel situado en la columna 807 y línea 434 de la imagen original (empleando el criterio del vecino más próximo). Este proceso se continúa hasta que se alcanza el vértice SW de la zona designada por el usuario, momento en el cual se culmina la corrección.

El resultado final del proceso aparece en la figura 6.57. Se trata de la banda 4 de la imagen de Madrid, tras aplicar el método de interpolación bilineal. Resulta patente la transformación geométrica que ha sufrido la imagen original, especialmente en lo que se refiere a su orientación y tamaño. Las esquinas de la imagen aparecen en color negro porque sobre esa zona no se han encontrado datos para la interpolación. Esto ocurre cuando seleccionamos una ventana excesivamente pequeña en la imagen original, de tal forma que al corregirla geométricamente, hay zonas de interés que no tienen datos. Para evitar esto, siempre conviene cortar una ventana más grande del área que pretendamos estudiar, de tal forma que al georreferenciar la imagen original, tengamos datos de salida en todas las zonas de interés.

6.3.3.4. Corrección con modelos digitales de elevación

La corrección geométrica basada en puntos de control ha sido el procedimiento más habitual para imágenes espaciales de alta resolución, Landsat o SPOT, y es el que está disponible en la mayor parte de los programas comerciales. Los resultados son, en la mayor parte de los casos, suficientemente satisfactorios. Sin embargo, en el caso de trabajar sobre zonas con un relieve muy quebrado, o con imágenes aéreas, en donde las deformaciones geométricas están estrechamente ligadas al modelado del relieve, sería necesario acudir a la información topográfica. La creciente conexión entre la teledetección y los SIG permite abordar estas operaciones de modo cada vez más accesible. Para realizar una corrección geométrica del efecto topográfico es preciso contar, previamente, con MDE. Como ya hemos visto, los MDE son de gran interés para el cálculo de reflectividades corregidas del efecto de iluminación. En el terreno de la corrección geométrica, la introducción de los MDE implica habitualmente realizar una rectificación diferencial, en donde cada ND se transfiera separadamente desde la imagen original a la resultante a partir de corregir la posición del píxel en función del desplazamiento debido al relieve (Palà y Pons, 1995). Cada coordenada *X*, *Y*, *Z* del MDE se transforma a la imagen mediante ecuaciones colineales, interpolando el ND de la imagen a partir de uno de los métodos antes comentados (Novak, 1992). También puede simplificarse la corrección, empleando un modelo polinómico donde la altura se introduce como una nueva variable independiente (Palà y Pons, 1995):

$$\hat{c} = a_0 + a_1 X + a_2 Y + a_3 Z + a_4 ZX + a_5 ZY \qquad \{6.72\}$$

lo que ofrece resultados mucho mejores al ajuste lineal simple, o incluso —aunque en menor proporción— al de segundo grado, cuando el terreno es montañoso. Esta inclusión de los datos altimétricos resulta clave cuando las imágenes no se adquieren verticalmente (como puede ser el caso de las adquiridas por el SPOT), en las que los errores debidos al relieve son muy notables.

6.3.3.5. Conveniencia de las correcciones geométricas

Antes de terminar el presente epígrafe, conviene hacer una breve reflexión sobre la necesidad y momento de las correcciones geométricas. Tradicionalmente esta operación se ha concebido como previa e imprescindible a cualquier análisis posterior de la imagen. En los últimos años, sin embargo, se prefiere restringir estas correcciones, relegándolas, siempre que sea posible, a la fase final del trabajo, una vez que se hayan obtenido los resultados finales de la interpretación.

La razón es doble: por un lado, se reduce el tiempo de tratamiento, pues, en lugar de corregir todas las bandas originales, basta corregir una, la que contiene la imagen resultado; por otro, se aborda la clasificación con los valores originales, evitando el efecto de promedio parejo a la tercera fase del proceso de corrección. Algunos autores han estudiado la importancia de este efecto (Smith y Kovalick, 1985). Las conclusiones de estos trabajos aconsejan realizar la clasificación con los valores originales, si bien no se encontraron grandes pérdidas de exactitud con el empleo de las imágenes corregidas.

Pese a los comentarios previos, conviene tener presente que, en determinadas aplicaciones, las correcciones resultan un paso obligado y previo a otros tratamientos. Este es el caso de las aplicaciones cartográficas en general —y, específicamente, en lo que se refiere a la realización de mosaicos (Hord, 1982; Verhoef y Peteri, 1984)—, así como los estudios multitemporales (7.3) o los que acudan a información auxiliar (cap. 9). En ambos casos, la precisión en el ajuste resulta un elemento fundamental.

En resumen, puede afirmarse que las correcciones geométricas son necesarias en la mayor parte de las aplicaciones de la teledetección espacial, aunque no en todas ellas como fase previa de trabajo. Si lo que se pretende es conectar los resultados de la clasificación con otras variables geográficas, o superponer dos clasificaciones realizadas en distinta fecha, las correcciones geométricas pueden abordarse al finalizar el proceso de análisis. Ahora bien, si pretende trabajarse con valores físicos (reflectividades, temperaturas) o introducir variables o imágenes auxiliares en la clasificación, es evidente que el registro geométrico es requisito previo a otros tratamientos.

CAPÍTULO 7

ANÁLISIS DIGITAL DE IMÁGENES: EXTRACCIÓN DE INFORMACIÓN TEMÁTICA

«Profesor: que te ilusione hacer comprender a tus alumnos, en poco tiempo, lo que a ti te ha costado horas de estudio llegar a ver claro.»

S. JOSEMARÍA ESCRIVÁ, *Surco*

1. **Generación de variables continuas**

Después de comentar los diversos tratamientos que conducen a disponer los datos de forma más idónea para extraer de ellos información temática de interés, dedicamos precisamente este capítulo a comentar las diversas técnicas que permiten extraer esa información de las imágenes. Hemos dividido la exposición en cuatro apartados según que el objetivo principal del análisis sea la obtención de variables continuas (7.1), la categorización de la imagen en clases temáticas (7.2), el análisis de cambios (7.3) o la medición de la estructura espacial del territorio (7.4). Este capítulo se complementa con los dos siguientes, dedicados, respectivamente, a verificar los resultados (cap. 8) y a conectarlos con otras fuentes de información en el marco de los SIG (cap. 9).

1.1. TÉCNICAS DE MODELADO EN TELEDETECCIÓN

1.1.1. *Teledetección cualitativa y cuantitativa*

Es obvio que el interés de la teledetección viene dado por su capacidad de proporcionarnos información temática, que cubra vacíos en nuestro conocimiento del territorio o, al menos, actualice lo que ya se había inventariado previamente.

En muchas ocasiones, se restringe el contenido informativo de la teledetección a la cartografía temática propiamente dicha. En otras palabras, las imágenes de satélite serían, bajo este punto de vista, sólo una herramienta para clasificar el territorio en categorías homogéneas, por ejemplo de cobertura del suelo, vegetación o cul-

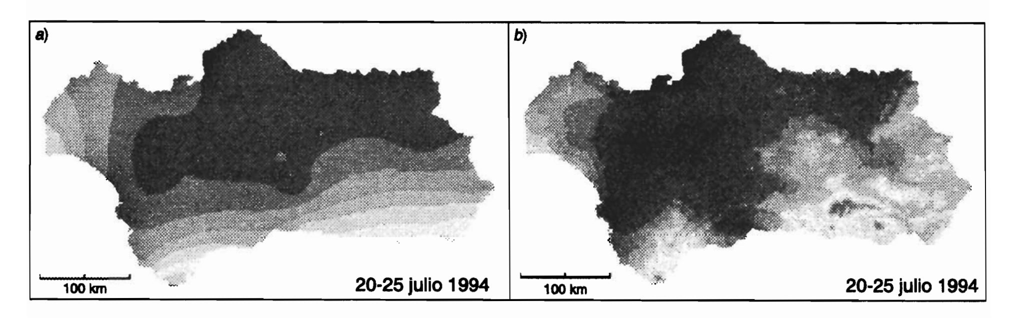


FIG. 7.1. *Mapas de ET estimada a partir de interpolación espacial (a) y regresión lineal (b) con variables derivadas de imágenes AVHRR (Sánchez y Chuvieco, 2000).*

tivos. Con ser de gran interés, este enfoque nos parece un tanto reduccionista. Conviene no perder de vista que una imagen de satélite es un conjunto sistemático de medidas cuantitativas sobre el territorio, con un nivel de resolución espacial inalcanzable en muestreos de terreno. Si esas mediciones se relacionaran satisfactoriamente con ciertos parámetros ambientales de interés, a partir de una imagen podría obtenerse la distribución espacial de dichos parámetros. Por ejemplo, en la mayor parte de los países la observación meteorológica se realiza a partir de una serie de puntos bastante dispersos en el territorio (donde se sitúan los observatorios). A partir de las mediciones que la teledetección realiza de la temperatura del suelo disponemos de una representación mucho más exacta de cómo las temperaturas se distribuyen en el espacio, ya que una imagen incluye medidas sistemáticas sobre el territorio (cada kilómetro, aproximadamente, en el caso del sensor AVHRR). La única manera de obtener una cartografía exhaustiva del territorio a partir de sensores convencionales sería mediante técnicas de interpolación espacial (Mitas y Mitasova, 1999), que serán tanto mas certeras cuanto mayor densidad de observatorios dispongamos y el territorio sea más homogéneo. Por ejemplo, la figura 7.1 nos permite comparar un mapa de evapotranspiración del cultivo de referencia (ET_r) obtenido mediante interpolación espacial de 26 estaciones meteorológicas en Andalucía, con el que se obtuvo mediante regresión lineal con variables derivadas de imágenes AVHRR (Sánchez y Chuvieco, 2000). Resulta obvio el carácter más realista de esta segunda estimación y su mejor adaptación a los rasgos del relieve regional.

Bajo esa óptica, podemos considerar la teledetección como una de las herramientas más potentes para generar información biofísica sobre el conjunto del territorio, a intervalos regulares y en condiciones comparables (sensor, altitud, hora de adquisición, etc.). Potencialmente las variables que pueden deducirse a partir de la teledetección son muy numerosas, siendo su rasgo común que están, de un modo u otro, relacionadas con la radiancia que reflejan o emiten los objetos, con su distancia al sensor o con su posición.

Podemos aquí establecer una primera distinción entre unas variables que son medibles de modo directo y otras que se derivan a partir de aquéllas. Las primeras son una función de los datos adquiridos por el sensor, por lo que pueden extraerse directamente de ellos si conocemos los parámetros de adquisición. Las más importantes son: la reflectividad en el espectro solar (VIS, IRC, SWIR); la temperatura en

el infrarrojo térmico; el coeficiente de retro-dispersión en micro-ondas; la altitud, a partir de la visión estereoscópica en el óptico; la medición de distancias con lídar y la interferometría radar, y la topografía de la superficie marina, a partir del altímetro de micro-ondas.

En cuanto a las variables indirectas, se trata de factores que se pueden derivar de las anteriormente citadas, gracias a que suponen una modificación de la señal recibida por el sensor. Por ejemplo, el contenido de clorofila no es una variable directamente medida por el sensor, pero modifica la reflectividad que éste recibe, por lo que puede estimarse indirectamente observando en qué bandas su efecto es más evidente y aislando ese componente de otros factores que también puede influir en tales bandas. Otros ejemplos de estas variables que pueden estimarse indirectamente a partir de la teledetección son el índice de área foliar, la radiación absorbida por la planta, la humedad del suelo o de las hojas, la turbidez del agua, la evapotranspiración o la productividad vegetal neta, entre otros que podrían citarse. Para obtener estas variables, tan críticas para un conocimiento más certero de nuestro medio ambiente, es preciso relacionarlas con la información contenida en las imágenes, estableciendo un modelo suficientemente fiable.

1.1.2. *Tipo de modelos en teledetección*

En teledetección, como en cualquier otra disciplina científica, podemos establecer una clasificación de los modelos disponibles en dos grandes categorías, según partan del diseño experimental para extraer principios teóricos a partir de él (modelos inductivos o empíricos), o propongan estimaciones a partir de analizar las relaciones teóricas entre los componentes de un determinado problema (modelos deductivos o teóricos). Las principales características de unos y otros, en el caso concreto de la teledetección, pueden resumirse como sigue (Danson *et al.*, 1995; Lillesand y Kiefer, 2000; Strahler *et al.*, 1986; Verstraete, 1994):

1. Los modelos inductivos o empíricos intentan establecer una relación numérica entre el parámetro a estimar y los valores del sensor, a partir de unas observaciones *in situ*, tomadas en el momento de adquirir la imagen. En otras palabras, se obtienen funciones de ajuste local que ponen en relación los datos de la imagen con el parámetro de interés. La técnica de ajuste más habitual es la regresión, en sus diversas variantes (Chuvieco *et al.*, 2004; Koutsias y Karteris, 1998; Morisette *et al.*, 2005; Silva *et al.*, 2004), aunque también hay algunos ejemplos de ajustes mediante redes neuronales (Fang y Liang, 2003; Pu y Gong, 2004; Riaño *et al.*, 2005; Vega-Garcia y Chuvieco, 2006).

   Las principales ventajas de los modelos empíricos son su sencillez (no requieren planteamientos a priori complejos) y la posibilidad de estimar su precisión, ya que se contrastan con unas observaciones de la misma variable que se estima. Su principal inconveniente atañe a su escasa capacidad de generalización, ya que sólo podrían aplicarse con las mismas o similares condiciones a la situación en que se generaron (condiciones ambientales del lugar, sensor, rango de la variable que se estima, condiciones de observación o atmosféricas, etc.).

2. En cuanto a los modelos teóricos o deductivos, pretenden establecer rela-

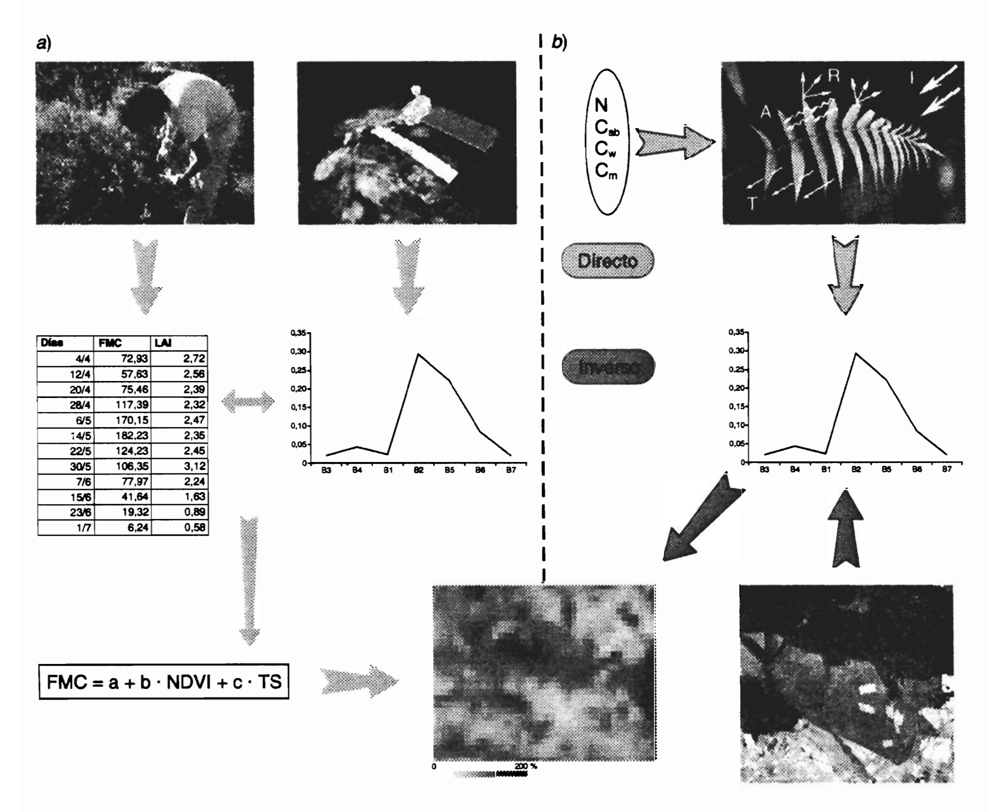
ciones de validez general, lo más independiente posible de unas determinadas condiciones de observación. Parten de demostrar la relación física entre el parámetro a estimar (por ejemplo, contenido de clorofila, LAI o ET) y la información espectral contenida en la imagen. Una vez comprobada esa relación, con algunos ejemplos empíricos, se invierte el modelo, de tal forma que pueda estimarse esa variable a partir de las imágenes (Dymond *et al.*, 2001; Fourty y Baret, 1997; Jacquemoud, 1993; Riaño *et al.*, 2005). Esto implica un proceso de ajuste que, en muchas ocasiones, resulta muy complejo y no siempre suficientemente preciso, ya que es necesario asumir condiciones que rara vez se dan en la naturaleza (p. ej., isotropía en las hojas, terreno plano, reflectividad lambertiana, etc.). Incluso aunque esta relación entre variable de interés e información espectral sea consistente, no resulta sencillo obtener esas variables espectrales, ya que es preciso eliminar de la imagen cualquier efecto extraño a la señal procedente de la cubierta. Esto implica modelar los efectos atmosféricos, la geometría de observación, el aporte del sustrato y las condiciones de mezcla con otras cubiertas, por citar sólo los más significativos. No obstante, y pese a las dificultades que presenta, el modelado deductivo ofrece más posibilidades que el inductivo para estimar variables biofísicas a partir de la teledetección, ya que facilita un mejor entendimiento de las variables que están influyendo en el proceso, además de requerir menos información auxiliar (trabajo de campo), simultánea a la adquisición, que sólo estará disponible cuando se haya planificado previamente un experimento con ese objetivo.

3. Algunos autores plantean una alternativa intermedia, que denominan modelos semi-empíricos, en donde se asume un previo modelado de la variable a estimar, aunque el ajuste se realice por ecuaciones empíricas. También se asigna esta denominación cuando los ajustes locales se basan sobre variables derivadas, como es el caso de los índices de vegetación (cap. 7.1.2), que ya cuenten con una relación teórica demostrada con las variables que pretenden estimarse (Danson *et al.*, 1995).

Como ilustración de estas ideas, vamos a revisar dos ejemplos de los distintos tipos de modelado que pueden realizarse en teledetección, empírico y teórico, utilizando como caso de estudio la estimación de la misma variable: el contenido de agua en la vegetación.

1.1.3. *Estimación empírica del contenido de agua en las plantas a partir de modelos empíricos*

Los modelos empíricos tienen una larga tradición en la investigación científica. Como es lógico, aunque se trata de ajustes locales, adaptados a las condiciones concretas que se miden, deben también tener una base física, ya que es necesario que las relaciones que se propongan estén apoyadas en un fundamento sólido. Como decíamos antes, este tipo de modelado tiene las ventajas de ofrecer una evaluación numérica de la precisión alcanzada en el modelo, ya que se pone en relación con datos medidos experimentalmente, además de ser relativamente sencillos de calibrar. Entre sus inconvenientes figura, por un lado, la complejidad de realizar las mediciones (especialmente cuando hablamos del trabajo de campo), y, por otro, el escaso carácter generalizador de los resultados. No obstante, cuando el modelo empírico



Días	FMC	LAI
4/4	72,93	2,72
12/4	57,63	2,56
20/4	75,46	2,39
28/4	117,39	2,32
6/5	170,15	2,47
14/5	182,23	2,35
22/5	124,23	2,45
30/5	106,35	3,12
7/6	77,97	2,24
15/6	41,64	1,63
23/6	19,32	0,89
1/7	6,24	0,58

FIG. 7.2. *Estimación del contenido de agua en las plantas a partir de modelos empíricos (*a*) y de simulación (*b*). La simulación puede hacerse en modo directo (estimar la reflectividad, variando los parámetros de entrada del modelo) o inverso (estimar el parámetro a partir de la reflectividad medida por el sensor).*

está bien fundamentado, la calibración en diversos lugares permite finalmente plantear funciones más generalistas, que pueden llegar a considerarse de validez global. Por ejemplo, el índice de peligro de incendios utilizado por el Servicio Forestal Canadiense *(Fire Weather Index)* (Van Wagner, 1974) tiene un desarrollo fundamentalmente empírico y está calibrado para las condiciones canadienses. Sin embargo, y hasta cierto punto sorprendentemente, funciona muy bien en otros entornos ambientales muy distintos al canadiense, por lo que se está empleando operativamente en lugares tan diversos como Indonesia y la cuenca mediterránea europea.

Presentamos como ejemplo de cómo plantear este tipo de modelos empíricos la estimación del contenido de agua en las plantas (fig. 7.2*a*). Nuestro departamento ha dedicado un considerable esfuerzo en los últimos cinco años a esta tarea, intentando entender mejor las relaciones entre la reflectividad y temperatura estimadas por teledetección y la dinámica del contenido de agua en las principales formaciones vegetales del mundo mediterráneo (pastizales y matorral), de cara a mejorar los sistemas actuales de prevención del peligro de incendio. Con este objetivo, hemos tomado muestras sistemáticas en el terreno para la primavera y el verano del período comprendido entre 1996 y 2006. Las muestras se han tomado siguiendo un estricto

protocolo (Desbois *et al.*, 1997), de tal manera que las series fueran comparables en el tiempo. La primera dificultad que se planteó en el estudio fue la elección del área de muestreo, ya que se requería contar con una zona relativamente plana y con suficiente homogeneidad para realizar estimaciones consistentes a partir de imágenes de baja resolución espacial (AVHRR, Vegetation y MODIS). Esto implicaba contar con grandes extensiones (entre 4 y 9 km^2) de cubierta relativamente uniforme, lo cual resultaba bastante complicado en un espacio tan heterogéneo como el mediterráneo. Por otra parte, esas superficies deberían cubrirse principalmente con pastizal y matorral, sin mezcla de terrenos cultivados, que modifican drásticamente la señal entre la primavera y el verano (después de la recolección). Afortunadamente, contamos con el apoyo de las autoridades del Parque Nacional de Cabañeros, que reunía las condiciones idóneas para este estudio, tanto desde el punto de vista topográfico como de cubiertas vegetales.

Otro problema que se planteaba, y que puede ser común a otros estudios empíricos, es la adecuada selección en terreno de las parcelas, de tal forma que sean suficientemente representativas del área observada por el sensor, por un lado, y sean manejables, por otro. Recoger información exhaustiva y repetitiva de una parcela de 9 km^2, por ejemplo resulta inabordable en terreno, por lo que es necesario aplicar algún criterio de muestreo que permita obtener medidas suficientemente significativas. En nuestro caso, se acotaron 3 parcelas para pastizal, a una distancia entre ellas de unos 5 km, y otras 2 para matorral, separadas unos 4 km. Las diferencias encontradas en la variación temporal del contenido de agua entre parcelas de la misma especie vegetal son prácticamente despreciables, lo que indica que los datos tomados en campo recogen adecuadamente las tendencias de las distintas especies que estamos analizando en el área de estudio.

El muestreo se realizó a intervalos regulares (cada 8 días en unos años y cada 16 en otros) coincidiendo los días con la adquisición del Landsat, y la hora de recolección con el paso del satélite NOAA. Como es lógico, en cualquier modelado empírico es importante que los datos de campo se tomen simultáneamente a la adquisición de las imágenes, siendo el requisito tanto más estricto cuanto mayor dinamismo tenga la variable. En nuestro caso, el contenido de agua en las plantas presenta una cierta inercia temporal (Brown *et al.*, 1989; Weber y Ustin, 1991), por lo que resultaba aceptable realizar simultáneamente el muestreo para correlacionar con datos TM/ETM+, MODIS, Vegetation y AVHRR, pese a que las imágenes se toman con 3-4 horas de diferencia.

Junto a los datos de campo, un modelo empírico precisa una buena fundamentación teórica y un sustento en observaciones espectrales controladas. En nuestro caso, la bibliografía sobre relaciones entre contenido de agua y reflectividad es muy amplia (Ceccato *et al.*, 2003), resumiéndose en el interés de las bandas del SWIR para una estimación directa, y las del IRC e IRT para una estimación indirecta, no válida en todas las especies (Bowman, 1989; Carter, 1991; Cohen, 1991; Cheng *et al.*, 2006; Gao, 1996; Jackson *et al.*, 1986; Leblon, 2001; Moran *et al.*, 1994; Riaño *et al.*, 2005; Stow *et al.*, 2005). Los resultados con sensores de microondas no son todavía muy concluyentes (Leblon, 2001; Moghaddam y Saatchi, 1999; Paloscia y Pampoloni, 1984). Para confirmar las experiencias de otros autores o matizarlas para las especies mediterráneas bien adaptadas a la sequía estival,

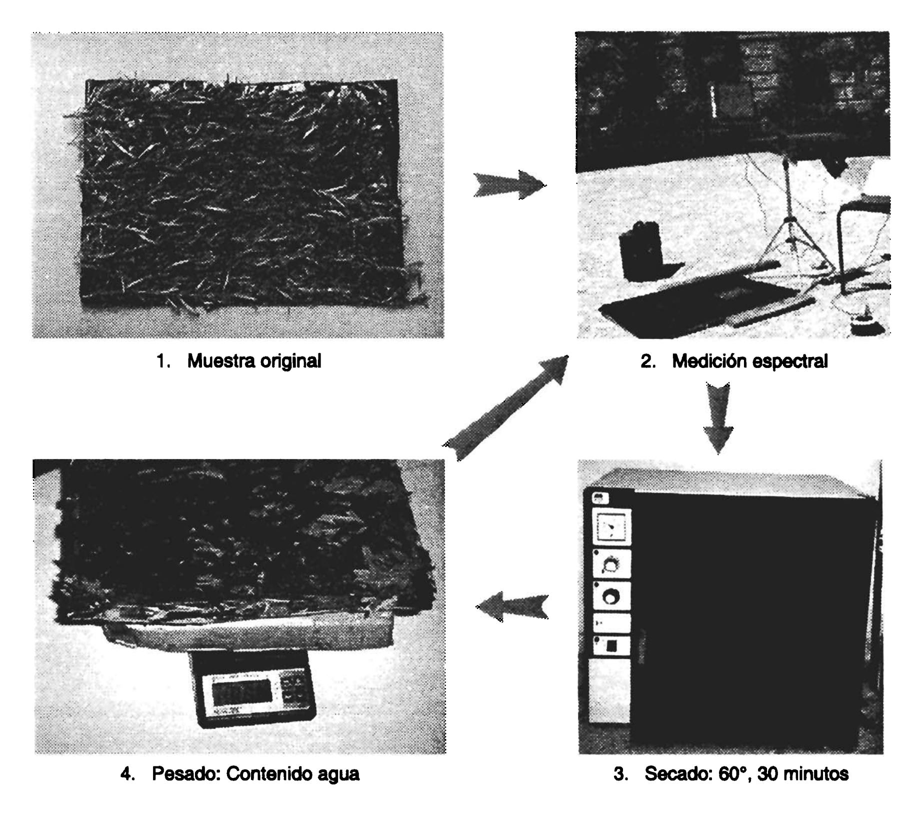


FIG. 7.3. *Diseño experimental para la estimación de humedad de la vegetación con espectro-radiómetro. La muestra se pesaba y media a intervalos regulares de secado.*

nos pareció oportuno realizar algunos análisis sobre las variaciones de reflectividad en espectros continuos para distintos niveles de contenido de humedad y diversas especies. Se realizaron diversas campañas de medición con un espectro-radiómetro GER 2600, capaz de observar un espectro continuo de 512 bandas en el rango de 0,4 a 2,5 μm, y con una cámara hiperespectral, que toma imágenes bidimensionales entre 0,9 y 1,7 μm. Se tomaron medidas de diversas especies de matorral y pastizales, utilizando bandejas de hojas con una geometría constante a lo largo de todo el experimento (fig. 7.3), para evitar efectos incontrolados de otros parámetros, como cambios en la morfología de las hojas, que suelen acompañar a la pérdida de humedad en algunas especies (Jackson y Ezra, 1985). Los análisis de las curvas espectrales para distintos contenidos de humedad de la misma especie permitieron observar cuáles eran las bandas más sensibles a esta variable, confirmando el gran interés de la región del SWIR para estos estudios (De Santis *et al.*, 2006).

Sobre esta base se planteó el análisis empírico que consistió en realizar ajustes de regresión entre los datos de campo y las variables derivadas de teledetección. Como hemos dicho, se emplearon datos del TM, Vegetation y AVHRR (Chuvieco *et al.*, 2004). El primero tiene la ventaja de ofrecer canales ópticos y térmicos, con dos bandas en el SWIR, buena resolución espacial y consistencia radiométrica,

TABLA 7.1. *Correlación de Pearson entre el FMC y los índices espectrales derivados de imágenes de los sensores AVHRR, Vegetation y TM (Chuvieco* et al.*, 2004)*

		NOAA-AVHRR		*SPOT-Vegetation*		*Landsat TM*	
	Variable	*r*	*significación*	*r*	*significación*	*r*	*significación*
Pastizal	NDVI	0,754	1,93 E-18	0,660	0,010	0,889	0,007
	NDII	—	—	0,693	0,006	0,892	0,007
	TS	–0,511	2,96 E-07	—	—	–0,773	0,041
	NDVI/TS	0,502	5,25 E-07	—	—	0,918	0,003
Jara *(Cistus ladanifer)*	NDVI	0,474	2,68 E-06	0,470	0,089	0,574	0,177
	NDII	—	—	0,786	0,0001	0,801	0,030
	TS	–0,722	1,43 E-17	—	—	–0,568	0,183
	NDVI/TS	0,717	4,80 E-17	—	—	0,732	0,060
Romero *(Rosmarinus officinalis)*	NDVI	0,529	1,00 E-07	0,515	0,059	0,723	0,066
	NDII	—	—	0,814	0,0001	0,526	0,245
	TS	–0,775	1,90 E-18	—	—	–0,528	0,223
	NDVI/TS	0,806	1,93 E-18	—	—	0,622	0,135
Matorral (promedio)	NDVI	0,501	3,32 E-07	0,509	0,062	0,574	0,177
	NDII	—	—	0,828	0,0002	0,756	0,048
	TS	–0,671	1,37 E-13	—	—	–0,481	0,274
	NDVI/TS	0,678	4,39 E-14	—	—	0,623	0,134

* TS es la Temperatura de Superficie; NDVI el índice de vegetación de diferencia normalizado y NDII el índice de infrarrojo normalizado. Ver sección 7.1.2 para la explicación de estos índices.

pero el inconveniente de su alto coste y baja resolución temporal. El segundo ofrece buena resolución temporal, coste intermedio y una banda en el SWIR, aunque no en el térmico. El tercero es de libre adquisición (nuestro propio departamento tiene instalado un sistema de recepción), y cuenta con buena resolución temporal y espectral, con la salvedad de no tener una banda en el SWIR hasta el lanzamiento del NOAA-15 (en 1998); además, es poco consistente en las series temporales, por el problema de los variados ángulos de observación que vimos anteriormente (6.6.2.3.4).

Un ejemplo de las correlaciones empíricas obtenidas, para el caso de las imágenes AVHRR en el año 1999, se incluyen en la tabla 7.1. Esos datos permiten confirmar las hipótesis planteadas en cuanto a la relación entre las variables de satélite y la dinámica del contenido de humedad (FMC). A continuación planteamos un modelo de regresión utilizando las variables más significativas. Como ejemplo de estos ajustes presentamos uno generado para el período estival (junio a septiembre) con datos AVHRR. Se emplearon 4 años consecutivos de datos para el ajuste (1996 a 1999), y otros dos para la validación (2000 y 2001). En este caso también se incluyeron parcelas en otros lugares alejados del Parque Nacional de Cabañeros, aunque con características ecológicas similares. Se plantearon dos ecuaciones, para matorral y pastizal, incluyendo como variable independiente una función del día del año (Chuvieco *et al.*, 2004):

$$FMCg = -57.103 + 284.808 \cdot NDVI - 0.089 \cdot TS + 136.75 \cdot FDg \quad \{7.1\}$$
$$FMCc = 70.195 + 53.520 \cdot NDVI - 1.435 \cdot TS + 122.087 \cdot FDc$$

donde FMC es el contenido de humedad estimado para pasto (g) y matorral (c), NDVI es el índice de vegetación de diferencia normalizada (ver 7.1.2), TS la Temperatura de Superficie, y FD una función del día del año, calculada de modo distinto para pastizal y matorral. El ajuste encontrado ofreció un coeficiente de determinación (R^2) de 0,737 para pastizal (significación < 0,001) y de 0,672 ($p < 0{,}001$) para matorral (fig. 7.4). En cuanto a los datos de validación, los ajustes también resultaron muy adecuados, con valores de R^2 por encima del 0,8 (Chuvieco *et al.*, 2004). En los últimos meses, hemos revisado este modelo, al comprobar que no funcionaba adecuadamente en años de extrema sequía, como ocurrió en 2005, planteándose un nuevo modelo de ajuste, con dos ecuaciones para años secos y húmedos. La decisión sobre emplear una u otra vendría dada por el balance hídrico que se observe a inicios de la primavera (Garcia *et al.*, 2008).

1.1.4. *Estimación del contenido de agua a partir de modelos de simulación*

La alternativa a los ajustes empíricos sería la aplicación de modelos deductivos, que permitan estimar los parámetros de interés a partir de los datos adquiridos mediante teledetección. Se basan en el análisis de los factores físicos que intervienen en los procesos de reflexión, absorción y dispersión de la radiación incidente, planteando métodos para estimar la reflectividad observada por el sensor a partir de

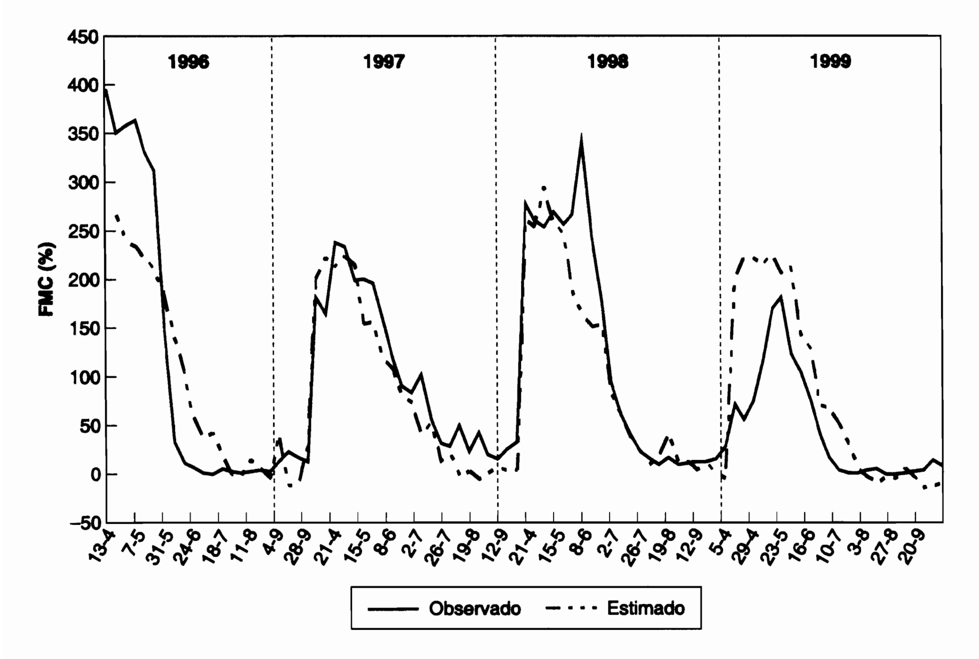


FIG. 7.4. *Ajuste entre valores observados y predecidos por el modelo empírico para la estimación del contenido de humedad (Chuvieco* et al., *2004).*

una serie de parámetros de entrada (propiedades ópticas de las hojas, arquitectura del dosel, ángulos de observación, etc.). Variando esos parámetros, pueden estimar la reflectividad resultante, de tal forma que el usuario pueda simular el impacto que tienen esos parámetros en la reflectividad que medirá el sensor. En este sentido, el uso de los modelos se considera en modo directo (fig. 7.2*b*), y resultan muy interesantes para entender mejor el peso que tiene cada factor de entrada en la señal resultado, de cara a plantear escenarios para la discriminación o análisis de sensibilidad (Bowyer y Danson, 2004; Chuvieco *et al.*, 2006). Suponiendo que esa estimación de la reflectividad sea correcta, el reto posterior sería invertir el modelo de simulación (fig. 7.2*b*), de tal manera que pudieran estimarse esos parámetros a partir de la reflectividad medida por el sensor (Liang, 2004).

En el ejemplo que venimos comentando, se trataría de estimar, en primer lugar, el efecto del contenido de agua de la planta sobre la reflectividad del dosel vegetal, mezclando su contribución con la de otros factores (como puede ser la clorofila o la cantidad de materia seca). En un segundo paso, se trataría de invertir el modelo, aislando de la reflectividad disponible en la imagen el componente de contenido de agua. La operatividad de este método frente a los ajustes empíricos dependerá de tres factores: contar con un buen modelo, con un buen método de inversión y con reflectividades calibradas (Jacquemoud *et al.*, 2000). Por un buen modelo nos referimos a que sea preciso, a que no requiera parámetros de entrada de muy difícil obtención, y a que sea lo suficientemente sencillo como para que la inversión del modelo pueda realizarse en un tiempo razonable.

Entre los modelos que se han planteado en las últimas dos décadas, podemos hacer una primera distinción entre los que se centran en el nivel de la hoja *(leaf optical properties models)* y los que estiman la reflectividad del conjunto del dosel vegetal *(canopy reflectance models)*. Entre los primeros, uno de los que ha tenido mayor aceptación en la literatura ha sido el denominado PROSPECT (Jacquemoud, 1990), que describe la reflectividad de una hoja a partir de considerarla como un pila de N láminas compuestas de elementos absorbentes y dispersores. Permite simular la reflectividad y transmisividad de la hoja considerando una serie de variables de entrada, relacionadas con su estructura y propiedades físico-químicas. Concretamente, en su última versión (Baret y Fourty, 1997), se requiere únicamente introducir la concentración de clorofila $a + b$ (en $\mu g\ cm^{-2}$), el espesor equivalente de agua (EWT, *Equivalent Water Thickness,* en $g\ cm^{-2}$), el contenido de materia seca (en $g\ cm^{-2}$), y el parámetro estructural N, que se refiere a la estructura interna de la hoja. Este parámetro es el más difícil de medir. Los mismos autores del modelo proponen estimarlo a partir del área específica de la hoja SLA *(Specific Leaf Area)*, calculada como el área por unidad de peso seco de la hoja, utilizando una relación empírica, como sería (Jacquemoud, 1990):

$$N = \frac{0,9\ \text{SLA} + 0,025}{\text{SLA} - 0,1} \qquad \{7.2\}$$

El modelo PROSPECT puede aplicarse a todo el espectro óptico (de 0,4 a 2,5 μm), para anchos de banda muy pequeños, de tal forma que permite comparar los resultados con espectrometría de laboratorio y sensores hiperespectrales.

A partir de este modelo, Ceccato *et al.*(2001) han realizado una serie de simulaciones para estimar qué bandas son más sensibles para obtener el contenido de agua en las hojas. En primer lugar han analizado el efecto de variar los distintos parámetros de entrada (clorofila, materia seca, N y EWT) en la reflectividad estimada para el rango completo del espectro óptico, observando que el EWT afecta solo al rango entre 0,9 y 2,5 µm (SWIR), pero no a las longitudes más cortas del IRC, ni al VIS. Sin embargo, la región del SWIR no sólo está afectada por el EWT, sino también por otras variables (concretamente N y el contenido de materia seca), con lo que necesitamos otra banda para aislar el EWT de los otros dos parámetros. Puesto que N y materia seca también influyen en la reflectividad del IRC, los autores proponen como mejor estimador del EWT un índice sintético que incluya una banda en el SWIR y otra en el IRC. Siguiendo un índice de estrés hídrico propuesto previamente por Hunt y Rock (1989), evalúan la capacidad predictiva de un cociente entre la reflectividad medida en 1,6 µm y en 0,82 µm y el EWT, encontrando un magnífico ajuste logarítimico ($r^2 = 0{,}919$).

Para las estimaciones de reflectividad a nivel del dosel vegetal se plantean otro tipo de modelos, que tienen en cuenta no sólo la reflectividad de la hoja, sino también la del suelo, así como la arquitectura de la planta y los ángulos de observación e iluminación. Según el punto de partida sobre el que realizan la modelización, los diversos modelos propuestos hasta el momento pueden clasificarse en cuatro grupos (Rencz, 1999, #3253; Zarco-Tejada, 1999, #3263):

1. Modelos de turbidez: tratan la cobertura vegetal como un medio infinito, horizontalmente uniforme y plano. Los elementos de la vegetación se consideran distribuidos de forma aleatoria en capas paralelas, formadas por pequeñas partículas reflectoras, que absorben dependiendo de sus propiedades ópticas definidas por la reflectividad y transmisividad (Verhoef, 1984, #3289). Estos modelos son los más extendidos, y se ha comprobado que funcionan bien para coberturas agrícolas (Jacquemoud, 1993; Jacquemoud *et al.*, 2000; Weiss *et al.*, 2001), pero no en el caso de cubiertas forestales, en donde resultan muy importantes los aportes del suelo y del sombreado de las copas, por lo que se recomienda ampliarlos utilizando modelos geométricos (Huemmrich, 2001). También se ha propuesto emplear modelos de dos capas para simular independientemente la respuesta del dosel forestal y de la vegetación por debajo de él (Kuusk, 2001).
2. Modelos geométricos, utilizados principalmente cuando las coberturas vegetales no son densas. La cobertura es estimada a partir de un ensamblaje de formas con dimensiones y propiedades ópticas simuladas (Li y Strahler, 1986). En los últimos años, los avances en la simulación por ordenador permiten plantear modelos tridimensionales de reflectividad, que consiguen acercamientos bastante realistas a las condiciones de una cubierta forestal compleja (Zarco-Tejada *et al.*, 1999).
3. Modelos híbridos, son una combinación de los dos anteriores, de turbidez y geométricos, y son utilizados en aquellos casos cuando la cobertura vegetal no se adecúa a ninguno de los casos anteriores. La modelización sigue siendo geométrica, pero la interacción del flujo con los elementos de la cobertura es realizada mediante modelos de turbidez. Estos modelos son los más complejos de diseñar y de cálculo más tedioso.

4. Modelos estocásticos, permiten la simulación de las posiciones y orientaciones de los elementos que forman la cobertura vegetal. Suelen utilizarse el método de Monte Carlo para seguir la trayectoria del fotón desde que llega a la cobertura e interacciona con los distintos elementos vegetativos que la componen. La trayectoria es seguida hasta que, de forma aleatoria, el fotón es absorbido (por lo tanto se pierde en la cobertura) o es reflejado (y por lo tanto captado por el sensor aerotransportado o espacial).

Entre estas distintas opciones de modelar la reflectividad del dosel, los más empleados son los modelos de turbidez, gracias a su relativa simplicidad, lo que facilita su inversión para estimar variables de interés (Jacquemoud *et al.*, 2000), y buen funcionamiento en coberturas homogéneas (principalmente cultivos). Posiblemente el más empleado hasta el momento haya sido el denominado SAIL *(Scattering from Arbitrarily Inclined Leaves)* propuesto por Verhoef (1984). El SAIL requiere como parámetros de entrada la reflectividad y transmisividad de la hoja, la reflectividad del suelo, la radiancia atmosférica, el área foliar (LAI), el ángulo cenital y acimutal solar y la distribución de los ángulos de inclinación de las hojas (LAD, *Leaf Angle Distribution*) respecto a la radiación incidente. Facilita la estimación de la reflectividad del dosel para un rango completo de ángulos de observación, proporcionando en consecuencia un buen análisis de la BRDF (6.6.2.3.4). Además de permitir analizar la sensibilidad de las distintas variables de entrada en el reflectividad estimada, y de obtener algunos de estos parámetros por inversión del modelo, el SAIL tiene también un gran interés docente, de cara a familiarizar al estudiante con la importancia de las distintas variables de entrada en la reflectividad que mide el sensor. En este sentido, existen dos versiones de SAIL de libre acceso realizadas con fines didácticos (Barnsley y Hobson, 1997; Danson, 1998). La figura 7.5 recoge un ejemplo de la modelización que facilita uno de estos programas (Barnsley y Hobson, 1997), obteniéndose los gráficos y valores de reflectividad para cuatro bandas con distintos ángulos de observación. Todos los parámetros de entrada son modificables, de tal manera que puede observarse el efecto que tienen en el cálculo de la reflectividad del dosel.

Los modelos de dosel y de hoja pueden enlazarse con cierta facilidad, ya que la simulación a nivel de hoja puede servir de entrada para la que realicemos a nivel de dosel. Por ejemplo, el modelo PROSPECT y SAIL pueden enlazarse dinámicamente, de tal forma que se analice el efecto de modificar los parámetros de hoja o dosel en la reflectividad resultante. La figura 7.6 muestra un ejemplo de esta simulación dinámica, empleando una versión didáctica de estos programas disponible en internet (http://www.geogra.uah.es/rtm/, último acceso mayo 2008).

En los últimos años se han publicado diversos trabajos sobre la estimación de la humedad de las plantas a partir de modelos de simulación previamente comentados (Ceccato *et al.*, 2002; Cheng *et al.*, 2006; Danson y Bowyer, 2004; Riaño *et al.*, 2005; Yebra *et al.*, 2008; Zarco-Tejada *et al.*, 2003). El proceso de trabajo suele partir de generar una tabla de referencia de valores de reflectividad, empleando unas combinaciones determinadas de parámetros de entrada. El rango de cada parámetro suele incluirse a partir de mediciones propias o bases de datos con medidas ecofisiológicas. Una de más conocidas es la del proyecto LOPEX (Hosgood *et al.*, 1994).

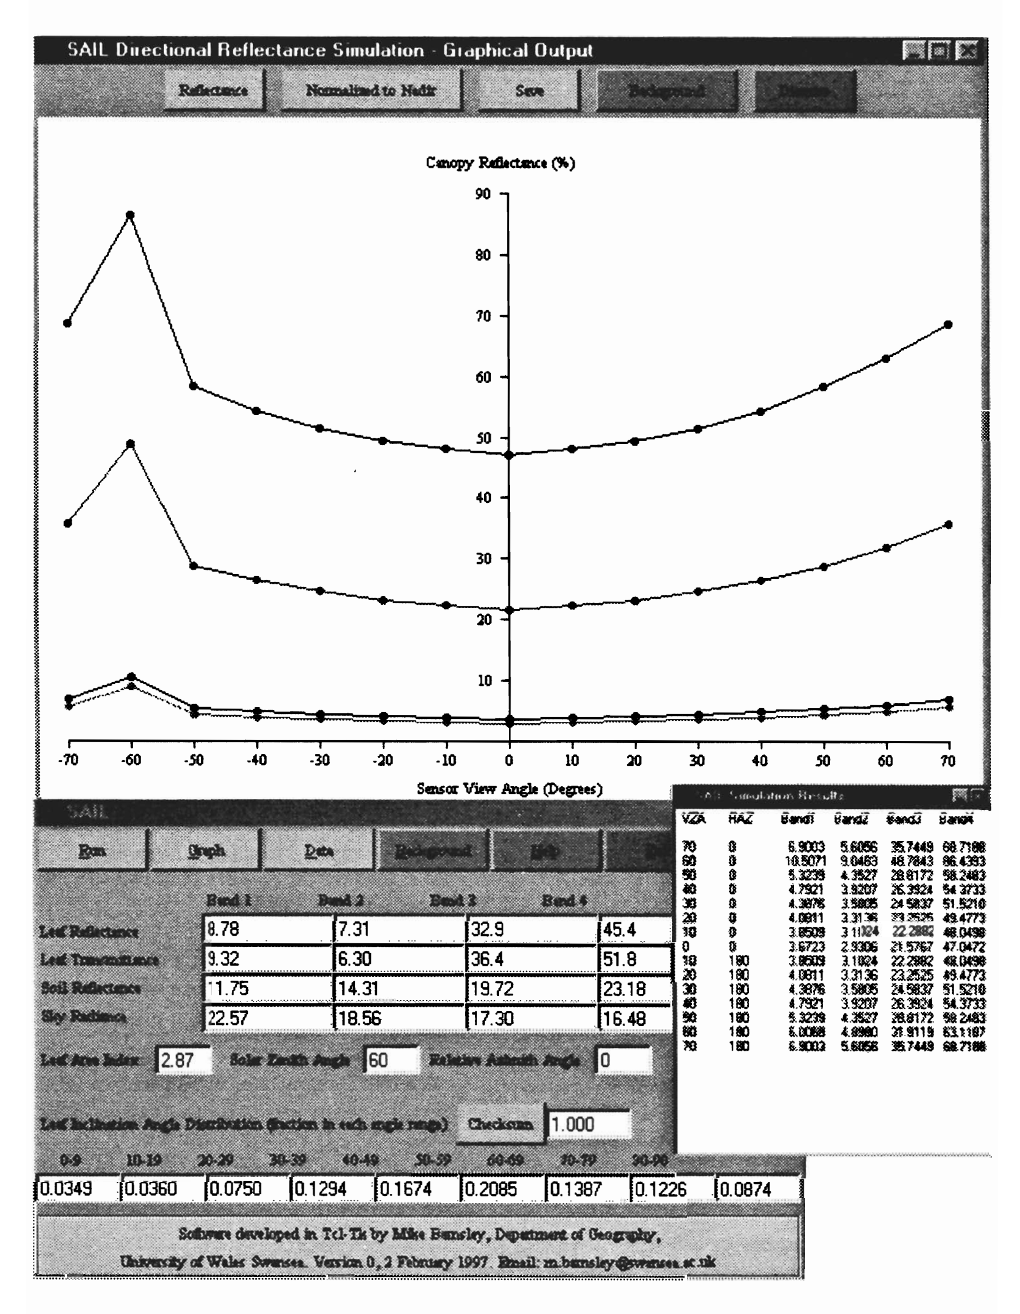


FIG. 7.5. *Resultados de la simulación con SAIL para cuatro bandas. Los datos de entrada figuran en la parte inferior. El programa corresponde a una versión de SAIL realizada por Barnsley y Hobson (1997) y está disponible en: http://stress. swan.ac.uk/˜mbarnsle/research/sail.htm*

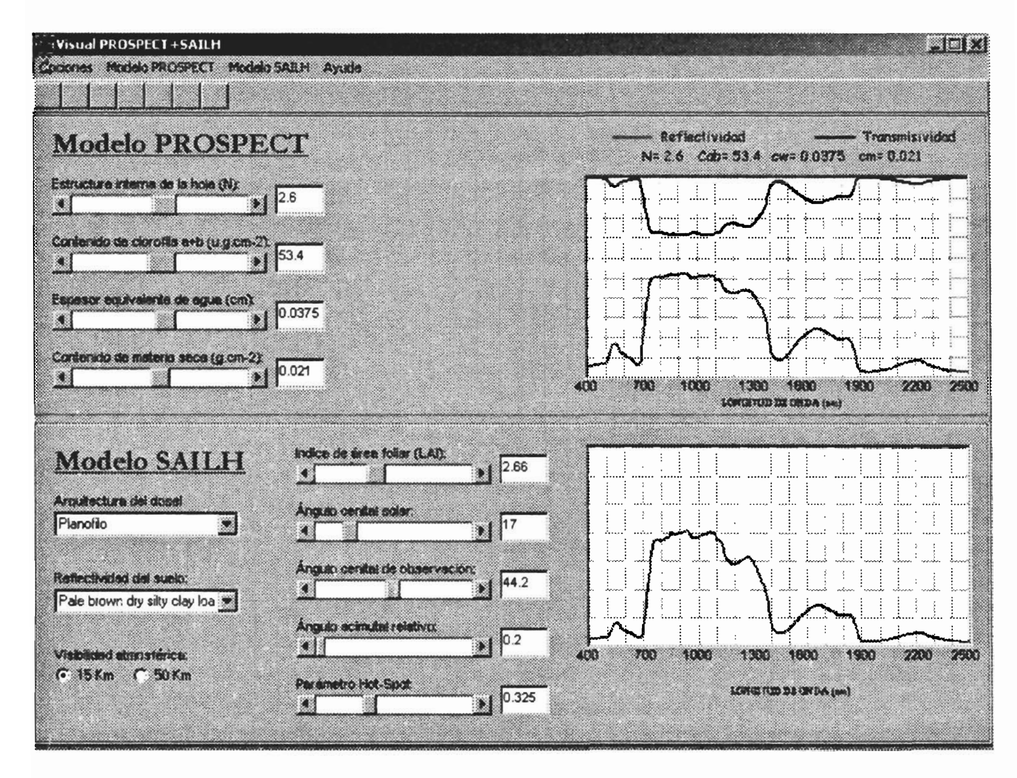


FIG. 7.6. *Simulación dinámica de la reflectividad de hoja y dosel empleando una versión didáctica de los modelos PROSPECT Y SAIL. El programa fue realizado por Elena Prado, como parte de su proyecto fin de carrera y está disponible en http://www.geogra.uah.es/rtm/*

Las reflectividades simuladas por los modelos sirven como clases de referencia para la inversión. Como la simulación se hace con bandas muy estrechas, para extraer la reflectividad más similar a la medida por un determinado sensor, se generan antes las reflectividades de ese sensor, aplicando los filtros espectrales de las bandas que contenga (habitualmente entre 0,4 y 2,5 µm). Seguidamente, se aplica algún criterio para encontrar qué reflectividad simulada es más similar a la medida por el sensor para cada píxel. Los más comunes son los ajustes de mínimos cuadrados, pero también se han empleado redes neuronales o mínima distancia angular (De Santis y Chuvieco, 2007; Koetz, 2005; Riaño *et al.*, 2005; Yebra *et al.*, 2008).

La comparación entre los resultados de estos modelos y los que se obtienen a partir de las funciones empíricas no resulta aún concluyente (fig. 7.7), pero se apunta una clara ventaja en cuanto a su capacidad de generalización y carácter más robusto (Yebra *et al.*, 2008). El problema principal de los modelos es que sean capaces de simular adecuadamente las condiciones de la vegetación, guardando un equilibrio en la simplificación que hacen de la realidad entre el rigor necesario para una buena estimación y la complejidad para que se puedan emplear operativamente. Por otro lado, estos modelos son en su mayor parte físicos, no ecológicos, y asumen que los parámetros de entrada son independientes, cuando esto pocas veces es cierto. Por ejemplo, la variación del agua en las plantas afecta a su contenido de clorofila o ma-

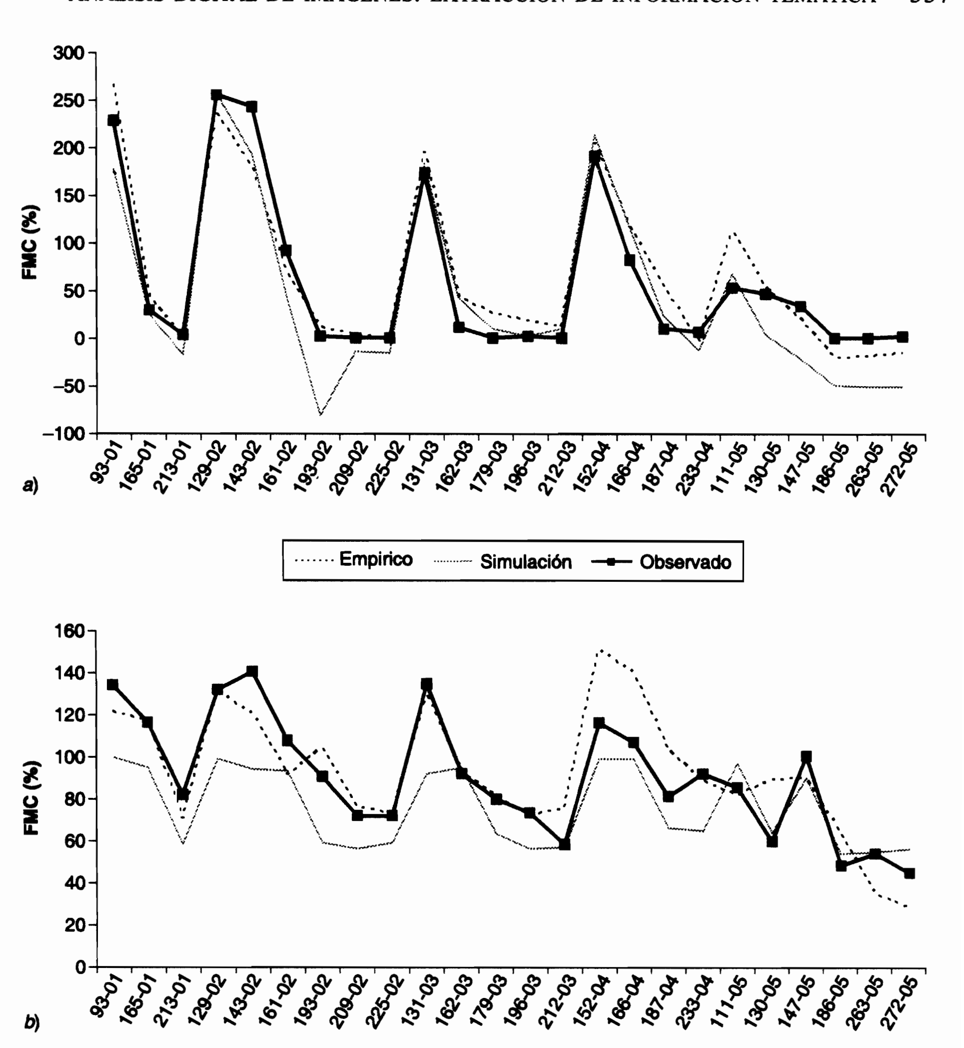


FIG. 7.7. *Comparación entre estimaciones de humedad de la vegetación basadas en modelos empíricos y de simulación, para pastizal (*a*) y matorral (*b*) (Yebra* et al.*, 2008).*

teria seca, por lo que no tiene mucho sentido plantear variaciones aleatorias de los parámetros de entrada, pues dan lugar a escenarios de simulación irreales. Esto es especialmente problemático en los procesos de inversión, que podrían seleccionar reflectividades de referencia generadas a partir de combinaciones imposibles (Combal *et al.*, 2002).

1.2. COCIENTES E ÍNDICES DE VEGETACIÓN

Como su nombre indica, un cociente o ratio implica efectuar una división, píxel a píxel, entre los ND almacenados en dos o más bandas de la misma imagen. Se

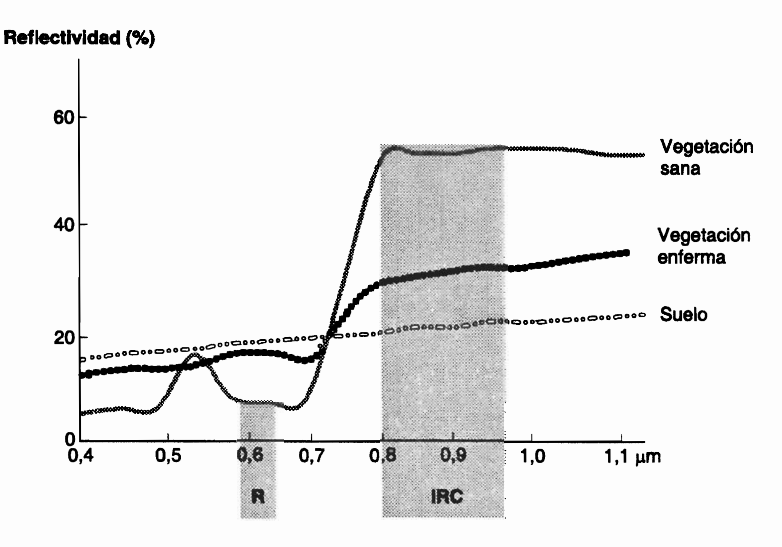


FIG. 7.8. *Contraste espectral de la vegetación sana entre las bandas R e IRC del espectro.*

utilizan ampliamente en dos situaciones: 1) para mejorar la discriminación entre dos cubiertas con comportamiento reflectivo muy distinto en esas bandas, por ejemplo para realzar suelos y vegetación en el VIS e IRC, y 2) para reducir el efecto del relieve (pendiente y orientación) en la caracterización espectral de distintas cubiertas. Como hemos visto, este último objetivo no se satisface plenamente, pues los cocientes sólo eliminan parcialmente el efecto del relieve, al no considerar que los efectos atmosféricos son también dependientes de la longitud de onda. En consecuencia, para esta finalidad resulta más recomendable aplicar correcciones del sombreado topográfico, centrando el interés de estos índices en mejorar la discriminación de las cubiertas vegetales y estimar algunas de sus variables biofísicas.

El empleo de los cocientes para discriminar masas vegetales se deriva del peculiar comportamiento radiométrico de la vegetación. Como ya vimos en el capítulo 2, la signatura espectral característica de la vegetación sana muestra un claro contraste entre las bandas del VIS —y especialmente la banda roja (0,6 a 0,7 µm)— y el IRC (0,7 a 1,1 µm). Mientras en el VIS los pigmentos de la hoja absorben la mayor parte de la energía que reciben, estas sustancias apenas afectan al IRC. Por esta razón, se produce un notable contraste espectral entre la baja reflectividad de la banda R del espectro y la del IRC, lo que permite separar, con relativa claridad, la vegetación sana de otras cubiertas (fig. 7.8). Cuando la vegetación sufre algún tipo de estrés (por ejemplo, por plagas o sequías intensas), su reflectividad será inferior en el IRC, aumentando paralelamente en el rojo (al tener menor absorción clorofílica), con lo que el contraste entre ambas bandas será mucho menor. En definitiva, podemos señalar que cuanto mayor sea la diferencia entre las reflectividades de la banda IRC y R, mayor vigor vegetal presentará la cubierta observada. Bajos contrastes indican una vegetación enferma, senescente o con poca densidad, hasta llegar a los suelos descubiertos o al agua, que presentan una reflectividad muy similar entre el IRC y el R, o incluso inferior en esta última (caso del agua o algunas nubes).

En este principio se apoyan la mayor parte de los denominados índices de ve-

getación (IV). Los más empleados son el cociente simple entre esas bandas (C), y el denominado índice de vegetación de diferencia normalizada (NDVI, *Normalized Difference Vegetation Index*) propuesto original por Rouse et al (1974):

$$C_i = \frac{\rho_{i,\,\mathrm{IRC}}}{\rho_{i,\,\mathrm{R}}} \qquad \{7.3\}$$

y

$$\mathrm{NDVI}_i = \frac{\rho_{i,\,\mathrm{IRC}} - \rho_{i,\,\mathrm{R}}}{\rho_{i,\,\mathrm{IRC}} + \rho_{i,\,\mathrm{R}}} \qquad \{7.4\}$$

donde indican las reflectividades del píxel **i** en la banda del infrarrojo cercano y del rojo, respectivamente. Esos índices se obtienen a partir de las reflectividades de las bandas 7 y 5, para el caso del sensor MSS; las bandas 4 y 3 para el TM y ETM+; la 3 y 2, para el HRV, y la 2 y 1 para el AVHRR y el MODIS.

Si bien la definición de estos índices se realiza a partir de reflectividades (lo que implica abordar las correcciones atmosféricas y topográficas vistas previamente), algunos autores no tienen inconveniente en emplear directamente los ND de la imagen, lo que podría ser admisible siempre que no se pretenda conceder un valor físico a los resultados. En ese caso, el cociente o índice de vegetación presentará una valoración relativa, aunque sigue manteniéndose el principio anterior: cuanto mayor sea el resultado, mayor vigor vegetal presenta la zona observada.

Aplicando un modelo teórico, Guyot y Gu (1994) concluyen que los valores del NDVI para imágenes Landsat y SPOT calculados a partir de ND subestiman entre 0,05 y 0,20 el valor calculado con reflectividades, siendo este error mayor con valores de NDVI inferiores a 0,5 y para las imágenes SPOT. En consecuencia, proponen una corrección que haga equivalente el cálculo con ND o reflectividades:

$$\mathrm{NDVI}_{TM,\rho} = \frac{\mathrm{ND}_{\mathrm{IRC}} - 0{,}801\,\mathrm{ND}_R}{\mathrm{ND}_{\mathrm{IRC}} - 0{,}801\,\mathrm{ND}_R} \qquad \{7.5\}$$

para imágenes Landsat-TM, y

$$\mathrm{NDVI}_{\mathrm{HRV},\rho} = \frac{\mathrm{ND}_{\mathrm{IRC}} - 0{,}663\,\mathrm{ND}_R}{\mathrm{ND}_{\mathrm{IRC}} + 0{,}663\,\mathrm{ND}_R} \qquad \{7.6\}$$

para imágenes SPOT-HRV.

Un aspecto de gran interés del NDVI, frente al cociente simple, es que varía entre unos márgenes conocidos (–1 y +1), lo que facilita notablemente su interpretación. Por ejemplo, podemos señalar como umbral crítico para cubiertas vegetales un valor de NDVI en torno a 0,1 y para la vegetación densa entre 0,5 y 0,7 (Holben, 1986).

Tanto el NDVI como el cociente simple se han empleado profusamente para estimar diversos parámetros de la cubierta vegetal, lo que les confiere un papel protagonista de cara a la evaluación ambiental, especialmente con un enfoque global. Entre los parámetros que se han relacionado satisfactoriamente con el NDVI están los siguientes:

1. Contenido de clorofila en la hoja, es la variable más directamente relacionada con este índice, ya que la absorción de la banda R está nítidamente influida por este parámetro. En consecuencia, el NDVI presenta correlaciones altas y linealmente positivas con la cantidad de clorofila en la hoja (Curran, 1989; Westman, 1994; Zarco-Tejada *et al.*, 2001).
2. Contenido de agua en la hoja, a través de correlaciones negativas y lineales, según algunos autores (Hardy y Burgan, 1999; Westman y Price, 1988), aunque para otros, en realidad esta estimación sólo se hace de modo indirecto, a través del efecto del estrés hídrico sobre el LAI y el contenido de clorofila (Ceccato *et al.*, 2003).
3. Flujo neto de CO_2, tanto a nivel local (Hall *et al.*, 1991), como global (Tucker *et al.*, 1986).
4. Radiación fotosintéticamente activa absorbida por la planta, APAR, con una relación directa y casi lineal (Asrar *et al.*, 1989), especialmente cuando las hojas son horizontales y el suelo es suficientemente oscuro (Sellers, 1989).
5. Productividad neta de la vegetación, relacionada con la APAR a través de un factor de eficiencia para cada planta (Steven y Jaggard, 1995). De modo indirecto, puede estimarse a partir del NDVI la biomasa verde y seca, aunque aquí los grados de ajuste varían mucho con los estudios, desde los muy buenos (Holben, 1980; Kennedy, 1989) hasta los bastante discretos (Tucker, 1979).
6. Índice de área foliar, LAI, que presenta una asociación positiva con el NDVI, especialmente cuando la vegetación no cubre totalmente el suelo, ya que a ciertos valores de LAI (por encima de 4, habitualmente), el NDVI se satura (Baret, 1995; Sellers, 1989). En consecuencia, más bien hemos de considerar que se trata de una relación asintótica (Sellers, 1987). Relacionado con este índice, se ha comprobado una alta correlación entre NDVI y porcentaje de cubierta verde (Kennedy *et al.*, 1994; Kerr *et al.*, 1992).
7. Cantidad de lluvia recibida por el dosel vegetal, lo que está directamente relacionado con su vigor vegetal, aunque habitualmente se presente un cierto desfase entre la precipitación y la respuesta de la cubierta vegetal (Millington *et al.*, 1994; Potter y Brooks, 2000; Taylor *et al.*, 1985).
8. Dinámica fenológica, a partir de seguir la evolución estacional de los parámetros antes señalados (Goetz *et al.*, 2006; Potter y Brooks, 2000).
9. Evapotranspiración potencial, inversamente relacionado con los índices de vegetación a través del vigor de la hoja y el estrés hídrico (Cihlar *et al.*, 1991; Sánchez y Chuvieco, 2000).
10. Efectos del fuego a partir de la pérdida de LAI y clorosis de las hojas soflamadas (Hammill y Bradstock, 2006).

Obviamente, si los índices de vegetación se relacionan bien con estas variables es porque ellas mismas están relacionadas entre sí (Huete *et al.*, 2002; Verstraete y

Pinty, 1996), a través de los mecanismos vitales de las plantas. El problema que se plantea en la interpretación cuantitativa de estos índices es la validez global de las funciones encontradas, ya que la mayor parte de los estudios citados previamente se basan en ajustes empíricos. El reto de los próximos años será plantear relaciones más generalizables, basadas tal vez en modelos físicos, que permitan extraer, a partir de estos índices, las variables de interés de modo más preciso y consistente.

Mientras se avanza en esa dirección, el NDVI —gracias a su facilidad de cálculo y fácil interpretación— se están empleando de modo rutinario en el seguimiento y evaluación de la dinámica global de la vegetación terrestre. Desde hace más de una década el programa internacional para el estudio de la geosfera y la biosfera (IGBP), junto a otros recursos nacionales, promueve la realización de mosaicos mundiales y diarios de NDVI a partir de imágenes NOAA. Estos datos se utilizan para seguir el efecto del cambio estacional en el vigor de las cubiertas vegetales, el efecto de procesos globales continuos, como puede ser el calentamiento terrestre, o de fenómenos esporádicos, como pueden ser los provocados por el Niño (Curran y Foody, 1994; Gutman, 1994). Las series multitemporales de IV se están empleado satisfactoriamente en el análisis de la desertización (Becker y Choudhury, 1988; Chen *et al.*, 1998; Tucker *et al.*, 1994), la deforestación tropical (Malingreau *et al.*, 1989; Nelson, 1994), la prevención de incendios forestales (Illera *et al.*, 1996; Paltridge y Barber, 1988), la cartografía de áreas quemadas (Chuvieco *et al.*, 2008; Fernández *et al.*, 1997; Fraser *et al.*, 2000; Gong *et al.*, 2006; Martín y Chuvieco, 1998; Pereira *et al.*, 1999) y la cartografía global de la cobertura del suelo (Loveland *et al.*, 1991; Millington *et al.*, 1994; Tucker *et al.*, 1985).

Varios autores han puesto de relieve el efecto de factores externos en el valor del NDVI, por lo que se han propuesto numerosas alternativas que intentan paliar algunos de estos problemas. De esta forma, la lista de IV disponibles es muy amplia (Bannari *et al.*, 1995), si bien la mayor parte presentan valores de correlación muy altos. No obstante, por su posible interés en distintas aplicaciones ambientales, revisaremos algunos de estos índices.

Entre los factores que modifican notablemente el comportamiento del NDVI figura la proporción de vegetación/suelo observada por el sensor. Los mismos valores de NDVI pueden corresponder a cubiertas vigorosas pero poco densas, o a cubiertas densas con poca vitalidad. Para incluir explícitamente el factor suelo, clave cuando se trabaja en zonas áridas, Huete y colaboradores propusieron incluir en la fórmula del NDVI un parámetro (L), que ajuste el índice a una reflectividad promedio de fondo (Huete, 1988; Huete *et al.*, 1992). De esta forma, se calcula el índice de vegetación ajustado al suelo (SAVI):

$$\mathrm{SAVI}_{i,j} = \frac{\rho_{i,j,\mathrm{IRC}} - \rho_{i,j,R}}{\rho_{i,j,\mathrm{IRC}} + \rho_{i,j,R} + L}(1+L) \qquad \{7.7\}$$

donde L, indica una constante para ajustar la línea vegetación-suelo al origen (los autores indican un posible valor en torno a 0,5 (Huete *et al.*, 1994). En estudios experimentales sobre campos de hierba y algodón, se comprobó que este índice reducía sustancialmente las variaciones inducidas por el suelo en comparación con el

NDVI y otros índices, en la mayoría de las condiciones de la vegetación (Huete, 1987).

Otro factor de importancia en el cálculo del NDVI es el efecto de absorción atmosférica, que tiende en principio a reducir el valor del índice (Cachorro *et al.*, 2000; Myneni y Asrar, 1994). Estos efectos se acentúan para los píxeles extremos en caso de observación oblicua, como ocurre en las imágenes del AVHRR o de otros sensores de ámbito global. Con imágenes AVHRR, este problema tiende a solventarse mediante técnicas de composición multitemporal, que intentan elegir en una serie de imágenes diarias el valor del píxel más cercano a una adquisición ideal (con atmósfera transparente y cerca del nadir), al coste de perder la resolución diaria (normalmente los compuestos se forman para períodos de entre 7 y 15 días). Esto garantiza que el NDVI seleccionado esté menos influido por ruidos externos a la cubierta observada. Entre las técnicas de composición más comunes se encuentra el máximo valor compuesto (Holben, 1986), que elige el valor mayor de NDVI de la serie diaria que se considere, si bien se han propuesto otras técnicas para obtener compuestos temporales de imágenes AVHRR (Cabral *et al.*, 2003; Cihlar *et al.*, 1994; Chuvieco *et al.*, 2005; Van Leeuwen *et al.*, 1999; Viovy *et al.*, 1992).

Como es lógico, esta solución para los problemas atmosféricos de los IV no resulta razonable para las imágenes de mayor resolución espacial (y menor temporal), ya que supondrían una inversión muy alta y perderíamos demasiada precisión temporal. Una alternativa sería ajustar el NDVI a las condiciones atmosféricas, teniendo en cuenta la diferente dispersión de los canales azul y rojo del espectro. De esta forma se define el denominado índice de vegetación atmosféricamente resistente (ARVI) (Kaufman y Tanré, 1992):

$$ARVI_{i,j} = \frac{\rho^*_{IRC} - \rho^*_{RA}}{\rho^*_{IRC} + \rho^*_{RA}} \qquad \{7.8\}$$

donde ρ^*_{IRC} indica la reflectividad aparente en el infrarrojo cercano y un factor que considera la diferencia de reflectividad entre el azul y el rojo, y se define como:

$$\rho^*_{RA} = \rho^*_R - \gamma(\rho^*_A - \rho^*_R) \qquad \{7.9\}$$

donde ρ^*_R y indican las reflectividades aparentes en el azul y rojo, respectivamente, y γ es un parámetro de calibración, que depende del tipo de atmósfera, aunque para la mayor parte de los casos es igual a 1.

Otro índice propuesto para reducir simultáneamente el efecto atmosférico y de cambios en el color del suelo es el denominado GEMI *(Global Environment Monitoring Index)*, definido para imágenes AVHRR como (Pinty y Verstraete, 1992):

$$GEMI = \eta \times (1 - 0{,}25 \times \eta) - \frac{\rho_R - 0{,}125}{1 - \rho_R} \qquad \{7.10\}$$

donde

$$\eta = \frac{2 \times (\rho_{IRC}^2 - \rho_R^2) + 1,5 \times \rho_{IRC} + 0,5 \times \rho_R}{\rho_{IRC} + \rho_R + 0,5}$$

El GEMI se ha empleado con buenos resultados en cartografía de áreas quemadas (Barbosa *et al.*, 1999; Chuvieco *et al.*, 2008; Riaño *et al.*, 2007) y de cubiertas vegetales en espacios semi-áridos (Leprieur *et al.*, 2000).

Finalmente, conviene citar el índice de vegetación mejorado (EVI, *Enhanced Vegetation Index*) definido por Huete et al. (2002) como una alternativa más sólida a los índices tradicionales, por ser más robusto frente a la aportación del suelo y de las influencias atmosféricas. El EVI se define como:

$$\text{EVI} = G \frac{\rho_{IRC} - \rho_R}{\rho_{IRC} + C_1\rho_R - C_2\rho_A + L} \qquad \{7.11\}$$

donde ρ_A, ρ_R, y ρ_{IRC} son las reflectividades del azul, rojo e infrarrojo cercano, respectivamente, L es la radiancia del fondo (la misma que en el SAVI), G es un factor de ganancia, y C_1 y C_2 son los coeficientes para corregir la influencia de aerosoles en la banda roja a partir de la azul. Para el cálculo global de este índice (fig. 13*), que se genera como un producto estándar del programa MODIS, se utilizan L = 1, C_1 = 6, C_2 = 7,5 y G = 2,5. Se ha comprobado en estudios recientes que el EVI es más sensible que el NDVI a rangos contrastados de cubierta vegetal, ofreciendo trayectorias temporales más consistentes (Saleska *et al.*, 2007).

La figura 7.9 presenta el NDVI calculado para la imagen Torre100. Se observan con nitidez las cubiertas de vegetación más vigorosa, como los pastizales próximos a Colmenar y Soto del Real, vigorosos en esta época del año. Los embalses ofrecen los valores más bajos de NDVI (A en la figura), así como las zonas urbanas de densa edificación (ver el casco urbano de Soto, B, o de Colmenar, C). Por su parte, las áreas de urbanización ajardinada presentan unos valores de NDVI más altos (D), sobre un entramado regular más oscuro (viales).

Todos los índices hasta aquí comentados se dirigen a realzar las cubiertas vegetales frente a otras superficies, a través del contraste que presenta la reflectividad de las plantas entre el IRC y el R. Ahora bien, en caso de que nos interese analizar otras variables en la vegetación, u otro tipo de cubiertas no vegetales, estas bandas pueden no ser las más idóneas. En esos casos, convendrá acudir a un análisis de las variaciones espectrales que introduce la variable de interés para proponer índices alternativos a los que hemos visto hasta el momento. Por ejemplo, si lo que se pretende es realzar la discriminación de las áreas forestales quemadas frente a otras cubiertas no afectadas por el fuego, los IV presentados no resultan una buena alternativa ya que no están diseñados para los rangos espectrales correspondientes a la vegetación quemada. En consecuencia, ofrecen rasgos de discriminabilidad peores que otros índices diseñados específicamente para esta finalidad (Chuvieco y Martín, 1999; Martín, 1998; Pereira, 1999; Trigg y Flasse, 2001).

De igual manera, cuando se pretenda analizar el contenido de agua en la vegetación, como ya hemos visto previamente, el espacio espectral más idóneo no está

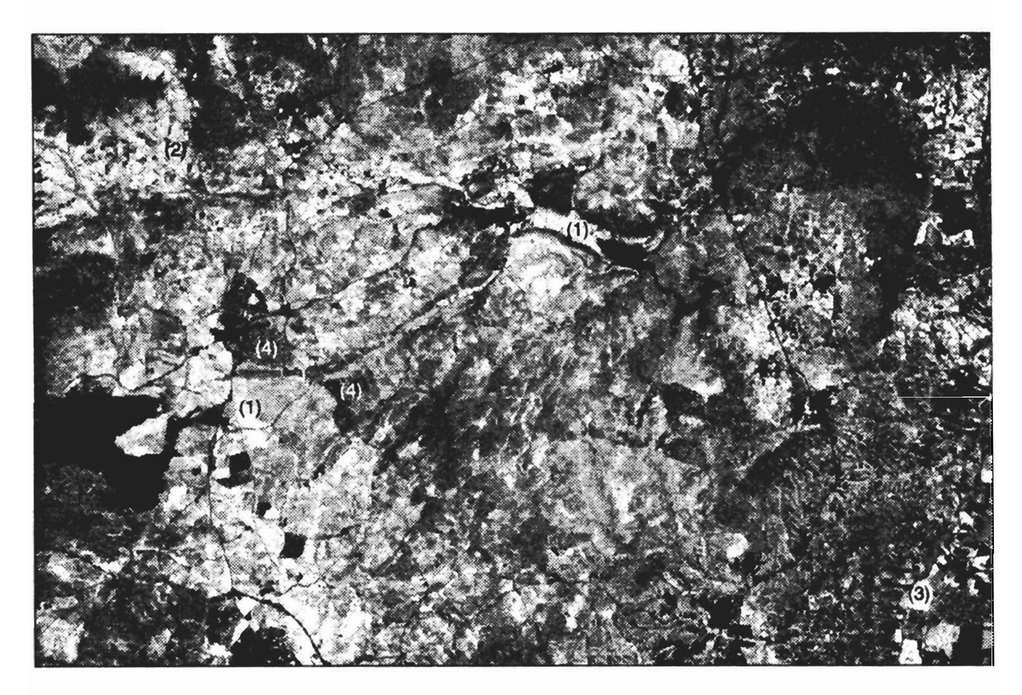


FIG. 7.9. *NDVI de la imagen Torre100. Se observan los valores más altos del índice NDVI para pastizales vigorosos (1), bosques (2), cultivos de regadío (3) y áreas residenciales ajardinadas (4).*

formado por las bandas IRC-R, sino más bien por las SWIR-IRC, ya que la absorción del agua se produce en el SWIR y no en el visible. Por tanto, al aumentar el contenido de agua en el suelo o la vegetación, disminuye paralelamente la reflectividad en el SWIR. Por su parte, el IRC informa sobre el grado de deterioro de la hoja a partir de su correlación negativa con el apelmazamiento que pueden producir distintas fuentes de estrés (como por ejemplo, el hídrico). Sobre esta base se han definido los denominados índices de contenido de agua, estrés hídrico o sequía (según los autores) que remarcan el contraste entre IRC y SWIR. Entre los propuestos cabe citar el NDII *(Normalised Difference Infrared Index)*, definido como (Hunt y Rock, 1989):

$$NDII = \frac{\rho_{IRC} - \rho_{SWIR}}{\rho_{IRC} + \rho_{SWIR}} \qquad \{7.12\}$$

donde ρ_{IRC} y ρ_{SWIR} son las reflectividades del IRC y SWIR, respectivamente. Se ha comprobado en varios estudios que este tipo de índices son más adecuados que el NDVI para estimar contenido de agua en vegetación (Ceccato *et al.*, 2001; Cibula *et al.*, 1992; Cohen, 1991; Chuvieco *et al.*, 2002; Gao, 1996; Riaño *et al.*, 2000; Ustin *et al.*, 1998).

También se ha comprobado que estos índices en el IRC-SWIR resultan más eficaces para cartografiar áreas quemadas que los basados en el IRC-R, puesto que la



FIG. 7.10. *Índice para realzar la humedad sobre la imagen Torre100. Los valores más altos de este índice se observan para agua (1), y, en menor magnitud, para los bosques de coníferas (2) y asfalto (3).*

señal quemada es más nítida en el SWIR, especialmente para separar la señal del carbón de otras zonas con reflectividades bajas, además de que hay menos alteraciones de otros factores externos, como la atmósfera (Chuvieco *et al.*, 2008; Martín *et al.*, 2005; Pereira, 1999).

Finalmente, se han propuesto otros cocientes de bandas para enfatizar cubiertas no vegetales, especialmente en trabajos de exploración minera. Este tipo de estudios sólo parecen viables en áreas de vegetación escasa, con objeto de obviar el efecto pantalla de la cubierta vegetal. En un trabajo realizado a partir de imágenes TM sobre el desierto del Mohave (California), se mostró el interés de los siguientes cocientes: TM5/TM7, para detectar rocas alteradas hidrotérmicamente, con alto contenido de arcillas, micas y rocas sulfatadas; TM5/TM4, para aislar las cubiertas vegetales del roquedo desnudo, y TM3/TM1, para aquellos materiales con importante presencia de limonita (Kruse *et al.*, 1993; Podwysocki *et al.*, 1985).

La figura 7.10 incluye un índice para realzar las cubiertas de agua y sombras de la imagen que estamos usando como ejemplo. Se trata de un índice normalizado entre las bandas azul y SWIR. Como puede observarse, se destacan claramente las láminas de agua y las cubiertas con reflectividades más bajas: coníferas, asfalto, zonas urbanas o en sombra.

1.3. Componentes principales

El Análisis de Componentes Principales (ACP) es una técnica bastante empleada en ciencias sociales y naturales. Su objetivo es resumir la información contenida en un grupo amplio de variables en un nuevo conjunto, más pequeño, sin perder una parte significativa de esa información.

El origen de esta técnica parece arrancar del campo de la sicometría: al analizar una serie de test de inteligencia, se intuía la presencia de una serie de factores, subyacentes a las variables medidas, que podrían explicar gran parte de la variación común en determinados grupos de variables. Por ejemplo, se comprobó que las puntuaciones obtenidas por los alumnos de física y matemáticas tendían a estar bastante relacionadas, así como las obtenidas por otros en historia y literatura. Esto hacía pensar en la existencia de otras variables más complejas, como la habilidad para el cálculo o la capacidad de abstracción, que permitirían resumir la información contenida en las variables originales. Esas nuevas variables, los componentes o factores principales, podrían derivarse a partir de las variables originales, estudiando sus relaciones comunes tal y como se miden en la matriz de varianza-covarianza. Los factores o componentes principales vendrían, por tanto, a ser como variables-resumen de las medidas inicialmente: un menor número de dimensiones, preservando lo más sustancioso de la información original.

Esta capacidad de síntesis ha sido la base de la aplicación del ACP en teledetección. La adquisición de imágenes sobre bandas adyacentes del espectro, implica con frecuencia detectar una información redundante, puesto que los tipos de cubierta tienden a presentar un comportamiento similar en longitudes de onda próximas. Por ello, las medidas realizadas en una banda pueden presentar una importante correlación con las deducidas de otra, haciendo una o varias de ellas prácticamente irrelevantes. En este contexto, el ACP permite sintetizar las bandas originales, creando unas nuevas bandas —los componentes principales de la imagen—, que recojan la parte más relevante de la información original. Esta síntesis resulta muy conveniente cuando se pretende abordar un análisis multitemporal (Maselli *et al.*, 1995), o cuando se intentan seleccionar las tres bandas más adecuadas para una composición en color (Chavez y Kwarteng, 1989; Green *et al.*, 1988). También se han utilizado bastante en la exploración geológica (Hervás, 1987). La selección de bandas no correlacionadas, o con mayor contenido de información, resulta especialmente crítica en el entorno del análisis hiperespectral (7.1.6), ya que al tener disponibles una gran cantidad de bandas, resulta complejo extraer la estructura dominante de la imagen (Palacios-Orueta *et al.*, 1999; Palacios-Orueta y Ustin, 1996; Ustin y Trabucco, 2000).

Por otra parte, y desde el punto de vista meramente estadístico, el ACP facilita una primera interpretación sobre los ejes de variabilidad de la imagen, lo que permite identificar aquellos rasgos que se recogen en la mayor parte de las bandas y aquellos otros que son específicos a algún grupo de ellas (Palacios-Orueta y Ustin, 1996). En definitiva, proporciona una mejor distribución de los datos, frente a esos ejes de variabilidad, lo que puede facilitar una identificación más atinada de las distintas cubiertas.

Como es bien sabido, el sentido y la fuerza de la correlación lineal entre dos

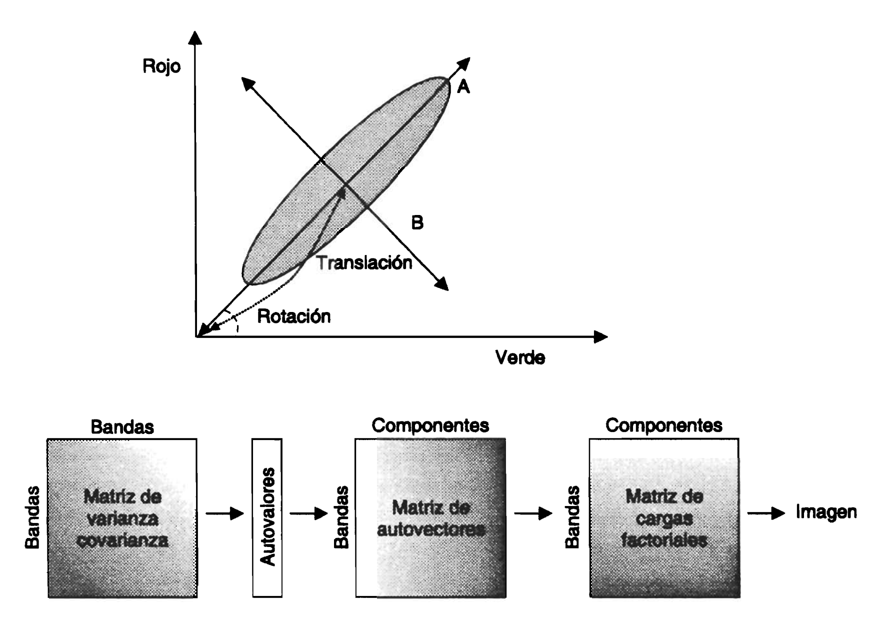


FIG. 7.11. *Proceso para la obtención de los componentes principales de una imagen.*

variables puede representarse gráficamente mediante un eje bivariado. En nuestro contexto, la nube de puntos indica la localización de los ND en las dos bandas consideradas. La elipse que limita estos puntos expresa gráficamente la fuerza de la correlación entre las dos bandas, tanto mayor cuanto más se aproxime a una recta, o —dicho de otro modo— cuanto mayor sea el contraste entre los dos ejes de esa elipse. En la figura 7.11 aparece una correlación positiva elevada con dos ejes de variación: el primero en el sentido de la correlación (A), y el segundo en el sentido de los residuales (B). Conviene considerar que este segundo componente es ortogonal al primero, lo que indica, en términos estadísticos, que los componentes principales no están correlacionados; esto es, que la información que contienen es específica.

Gráficamente se intuye que una rotación de los ejes X, Y hacia las direcciones A, B, mejorará la disposición original de los datos, y probablemente también la separación entre los grupos de ND homogéneos en la imagen. Esa rotación se obtiene, simplemente, aplicando una función del tipo:

$$CP_1 = a_{11}\ \mathrm{ND}_i + a_{12}\ \mathrm{ND}_k \qquad \{7.13\}$$

donde CP_1 indica el valor correspondiente al primer componente principal, obtenido a partir de los ND originales de las bandas i y k, tras aplicarles unos determinados coeficientes a_{11} y a_{12}. Desde el punto de vista geométrico, y como puede observarse en la figura 7.11, este nuevo eje sólo supone una rotación de los originales. En ocasiones, puede ser de gran interés acompañar la rotación con una traslación de los ejes, situando el origen de coordenadas en los valores mínimos de las dos bandas implicadas en el proceso. Basta, para ello, añadir dos constantes a_{01} y a_{02} a la ecuación arriba señalada.

En términos más generales, los componentes principales de una imagen se obtienen de acuerdo a:

$$CP_j = \sum_{i=1,p} a_{i,j} \text{ND}_i + R_j \qquad \{7.14\}$$

donde CP_j indica el ND correspondiente al componente principal j, $a_{i,j}$ el coeficiente aplicado al ND de la banda i para generar el componente j y R_j una constante para desplazar el eje del origen y evitar valores negativos. Otra posibilidad es estandarizar los valores resultantes, por ejemplo a 0-255, evitando la constante. Como hemos indicado, hay tantos componentes (p) como bandas, pero la forma de extraer esos componentes implica que sólo los primeros tienen una información significativa.

La obtención de los *CP* de una imagen implica una transformación matemática compleja, que no parece oportuno detallar aquí.[1] En términos sencillos, el proceso puede resumirse en los siguientes pasos. A partir de la matriz de varianza-covarianza de las bandas que componen la imagen original, se extraen los autovalores (ξ_j) que expresan la magnitud del vector de cada uno de los nuevos componentes, y, en última instancia, la proporción de información original que retienen. Este dato resulta de gran interés para decidir qué componentes principales son más interesantes; habitualmente los que mayor información original retengan. Tal y como se obtienen los *CP*, el autovalor va disminuyendo progresivamente, del primero a los últimos, pues se pretende maximizar sucesivamente la varianza extraída en el análisis. La varianza original explicada por cada componente se calcula como la proporción de su autovalor frente a la suma de todos los autovalores:

$$V_i = \frac{\xi_j}{\sum_{j=1,p} \xi_j} \qquad \{7.15\}$$

siendo p el número total de componentes.

Junto a la magnitud del vector, nos resulta también de gran interés conocer su dirección, de cara a poder interpretar el sentido de las nuevas variables. Esto supone calcular la relación de cada componente con las variables originales. De igual forma, para calcular las ecuaciones que servirán para obtener las nuevas imágenes, se precisa contar con los coeficientes de la transformación. Ambos aspectos pueden abordarse a partir de la matriz de autovectores. El autovector indica la ponderación que debe aplicarse a cada una de las bandas originales para obtener el nuevo *CP* ($a_{i,j}$ en la fórmula {7.14}). Simplificando las cosas, equivalen a los coeficientes de regresión en una transformación lineal estándar, siendo las bandas de la imagen las variables independientes y los *CP* las dependientes.

A partir de los autovectores, se calcula la matriz de correlación entre *CP* y bandas de la imagen, lo que nos permite conocer el sentido espectral de estos componentes. Basta aplicar:

1. En el contexto del tratamiento digital de imágenes puede consultarse Short (1982, pp. 174 y ss.), González y Wintz (1977), Thomas *et al.* (1987) y Richards (1993).

TABLA 7.2. *Matriz de varianza-covarianza de la imagen Torre100*

	B1	*B2*	*B3*	*B4*	*B5*	*B7*
B1	102,83					
B2	107,91	123,68				
B3	156,30	176,07	271,58			
B4	71,71	114,86	127,63	583,76		
B5	149,94	183,70	275,91	340,63	516,96	
B7	141,22	161,53	251,25	157,26	369,24	314,29

1. Los números refieren a ND. No se ha incluido la banda térmica.

$$r_{i,j} = \frac{a_{i,j}\sqrt{\xi_j}}{s_i} \qquad \{7.16\}$$

donde $r_{i,j}$ indica el coeficiente de correlación entre el componente j y la banda i; $a_{i,j}$ el autovector de ese componente en la misma banda; ξ_j, el autovalor del componente j, y s_i la desviación típica de la banda i.

El último paso es obtener una imagen de los componentes principales, a partir de {7.14}. Obtenida la imagen de los *CP*, pueden éstos representarse en blanco y negro o color, obteniéndose una nueva visualización de la zona de estudio. Para ello, convendrá escalar los resultados en el rango más común en un equipo de visualización (0 a 255). Una forma sencilla de abordar este proceso sería realizar una pequeña muestra de los valores resultantes, con objeto de estimar los valores máximos y mínimos, aplicando luego alguno de los procedimientos para expandir el contraste que se ha mencionado anteriormente.

Para ilustrar el interés del ACP en la interpretación digital de imágenes, se aplicó esta técnica sobre las seis bandas no térmicas de la imagen Torre100. A partir de una muestra sistemática de 1 de cada 8 píxeles, se obtuvo la matriz de varianza-covarianza para esas bandas (tabla 7.2). Sobre esa matriz se calcularon los autovalores de la imagen, realizando una previa estandarización, con objeto de paliar el efecto de la distinta variabilidad entre bandas. Los autovalores (ξ_j) extraídos fueron: 1365,72, 410,24, 115,60, 9,64, 9,05 y 2,83. De acuerdo a {7.15} la varianza original asociada con cada uno de estos componentes resultó ser 71,39 % para el primer componente; 21,44 % para el segundo; 6,04 % para el tercero; 0,50 % para el cuarto; 0,47 % para el quinto, y 0,15 % para el sexto. De acuerdo a estos porcentajes, se seleccionaron únicamente los tres primeros componentes, que retenían un total del 98,87 % de la varianza original de la imagen.

El sentido espectral de estos componentes, se obtuvo a partir de la matriz de autovectores, en donde se evidencia la asociación entre cada componente y las bandas originales. Como puede analizarse en la tabla 7.3, el primer componente ofrece un promedio ponderado de todas las bandas. Recoge, en consecuencia, una valoración de las características espectrales comunes a todas ellas, lo que puede asimilarse con el brillo general de la imagen, similar al aspecto que podría presentar una banda pancromática. Esta interpretación es bastante generalizable para el primer

TABLA 7.3. *Matriz de varianza-covarianza de la imagen Torre100*

	B1	*B2*	*B3*	*B4*	*B5*	*B7*
CP1	0,213	0,258	0,374	0,462	0,589	0,434
CP2	–0,213	–0,171	–0,354	0,834	–0,041	–0,321
CP3	0,381	0,400	0,464	0,238	–0,585	–0,284

componente de la mayor parte de las imágenes tomadas en el espectro solar, ya que el factor más común a la variación espectral en estas longitudes de onda es la reflectividad promedio. El segundo componente muestra una importante asociación positiva con la banda 4, apenas perceptible con la 5 y moderadamente negativa con el resto. En definitiva, está evidenciando el contraste espectral entre el IRC y el resto de las bandas consideradas (VIS y SWIR), lo que muestra una valoración del vigor vegetal de la imagen. Finalmente, el tercer componente ofrece un claro contraste entre el VIS-IRC y el SWIR, con correlaciones positivas para las primeras bandas y negativas para las segundas. Esto parece indicar una valoración del contenido de agua, por lo que le denominaremos como componente humedad.

Las imágenes de los *CP* resultantes parecen demostrar esta interpretación preliminar. El primero presenta una fisonomía muy similar a la de una imagen pancromática, con valores promedio de las distintas cubiertas: bajos valores en el agua y la vegetación, medios en los espacios edificados, y altos en los suelos descubiertos (fig. 7.12*a*). El segundo componente evidencia los sectores con una actividad clorofílica más intensa, como son los pastizales y cultivos de secano (recuérdese que la imagen está tomada muy cerca de la primavera), ofreciendo tonos medios para los pinares del vértice SW y las diversas urbanizaciones, y tonos oscuros para los suelos descubiertos, agua y vías de comunicación (fig. 7.12*b*). Por último, el tercer componente remarca con claridad las láminas de agua, vías de comunicación y espacios edificados, que ocupan el intervalo más alto de la imagen. Ofrecen tonos medios los pinares y las áreas de caducifolias todavía sin hojas, seguramente por el efecto de sombras en el suelo. Por el contrario, la vegetación manifiesta tonos gris-medio a oscuro, en función de su vigor, mostrando los matorrales tonos intermedios y los cultivos de secano más oscuros (fig. 7.12*c*).

La capacidad de síntesis propia del ACP la hacen una técnica muy apropiada como filtro previo para el análisis multitemporal, cuando se van a utilizar varias imágenes en una sola clasificación. En ese caso, el ACP sirve para retener la información más significativa de cada período. Posteriormente, se combinan los *CP* de cada fecha con objeto de facilitar una mejor discriminación de cubiertas con perfiles estacionales marcados (Joly *et al.*, 1983; Maselli *et al.*, 1995; Siljeström y Moreno, 1995). Más original resulta su aplicación para estudiar series temporales de imágenes en estudios sobre cambio global de la vegetación (Eastman y Fulk, 1993), lo que permite obtener, además de las tendencias generales de las cubiertas, información residual de gran interés para detectar anomalías. Posteriormente, analizaremos con más detalle el empleo del ACP como técnica para la detección de cambios entre dos imágenes de distinta fecha (ver sección 7.3.4).

Un problema inherente al ACP es la dificultad de establecer una interpretación

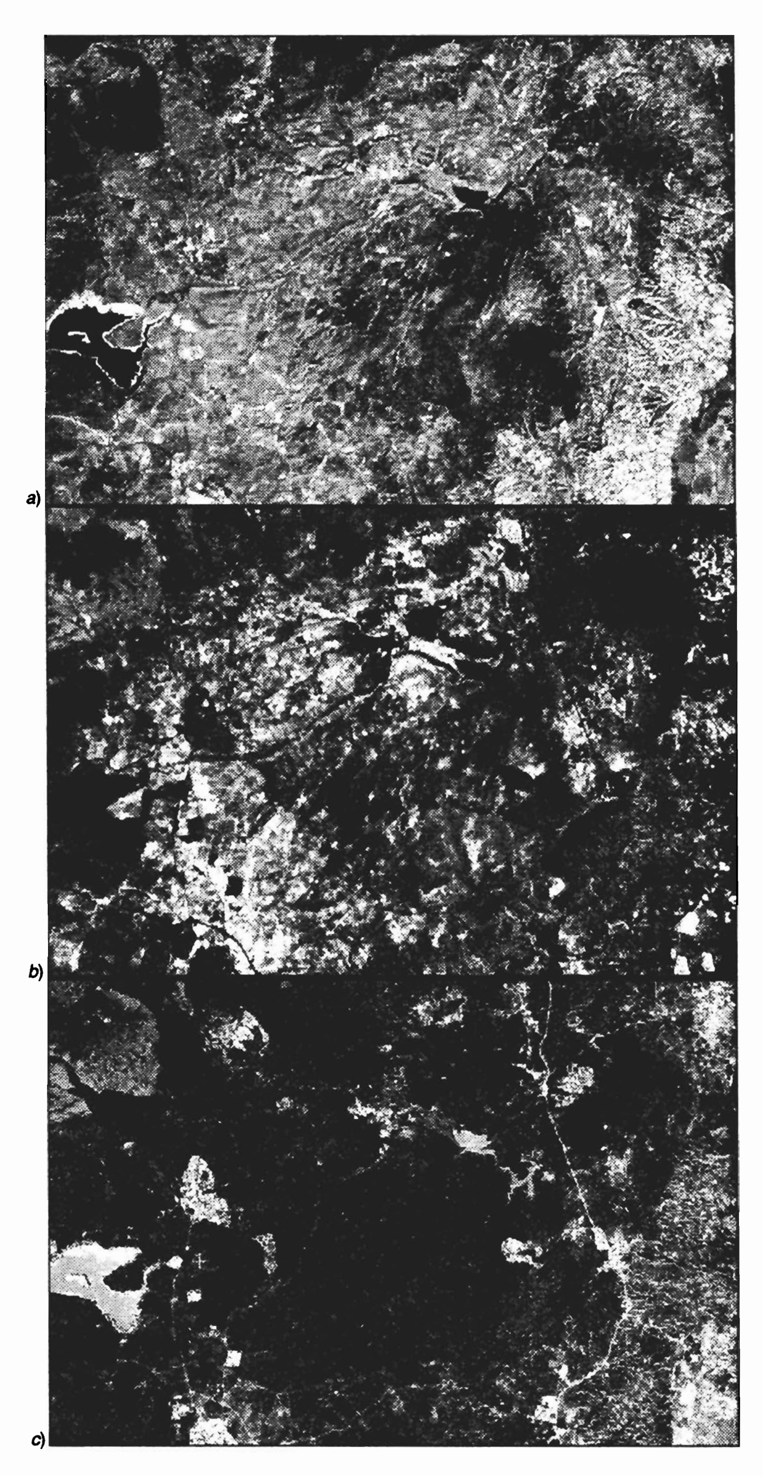


FIG. 7.12. *Componentes principales de la imagen Torre100:* (a) *CP1;* (b) *CP2;* (c) *CP3.*

a priori de los componentes, ya que la transformación es puramente estadística y, por tanto, muy dependiente de las características numéricas de la imagen. Algunos autores sugieren que el primer componente siempre indica el brillo general y el segundo el verdor (Ingebritsen y Lyon, 1985). No obstante, esta afirmación asume que en la imagen existe una cantidad suficiente de cobertura vegetal. De otra forma, el componente de vegetación puede ser el tercero o cuarto. En definitiva, no pueden aplicarse reglas generales para la interpretación de los CP.

1.4. Transformación «*Tasseled Cap*» (TTC)

Al igual que el ACP, esta transformación se dirige a obtener unas nuevas bandas, por combinación lineal de las originales, con objeto de realzar algunos rasgos de interés en la escena. La diferencia frente al ACP estriba en que la TTC ofrece unos componentes de significado físico preciso, esto es, independientes del tipo de imagen que se esté analizando.

La TTC fue ideada por Kauth y Thomas en el marco del proyecto LACIE *(Large Area Crop Inventory Experiment)*, desarrollado por la NASA y el Departamento de Agricultura estadounidense (USDA) en los años setenta, con objeto de mejorar la predicción de cosechas. Dentro de este proyecto, se pretendió modelar los componentes fundamentales de variación en una imagen MSS, describiendo sus características físicas desde el punto de vista del seguimiento de cultivos (Kauth y Thomas, 1976). A partir de una serie de imágenes de zonas agrícolas, se trató de sintetizar los ejes de variación espectral de los cultivos en una figura tri-dimensional, de aspecto parecido a un gorro con borlas *(tasseled cap)*. Considerando las bandas roja e infrarroja, la base de ese gorro se define por la línea de suelos, en donde se sitúan los distintos tipos de suelo, de acuerdo a su brillo y color (fig. 7.13). Según el cultivo va ganando en vigor, tiende a separarse de la línea del suelo, aproximándose al eje de la banda infrarroja, y convergiendo en un punto cuando se produce la máxima madurez. A partir de ahí el cultivo tiende a marchitarse, retornando hacia la línea de suelos.

La TTC tiende a poner más en evidencia el comportamiento espectral de la vegetación y el suelo, a partir de crear nuevos ejes mejor ajustados a ese espacio físico. En ese nuevo sistema de coordenadas, se pretende que sea más nítida la separación entre ambas cubiertas. Para el caso de las imágenes MSS, sobre las que se desarrolló esta transformación, los nuevos ejes se obtuvieron a partir de:

$$u_j = R_i' x_i + c \qquad \{7.17\}$$

donde u_j indicaba el vector correspondiente a la imagen transformada; x_i, el vector de entrada; R_i', el vector de coeficientes de transformación, y **c** una constante para evitar valores negativos. Los autores sugerían un valor $c = 32$.

Sobre el conjunto de imágenes de su muestra, los autores del trabajo distinguían tres componentes: uno, denominado brillo *(brightness)*, suma ponderada de las cuatro bandas originales; otro, denominado verdor *(greenness)*, relacionado con la actividad vegetativa; un tercero conocido como marchitez *(yellowness)*, que pre-

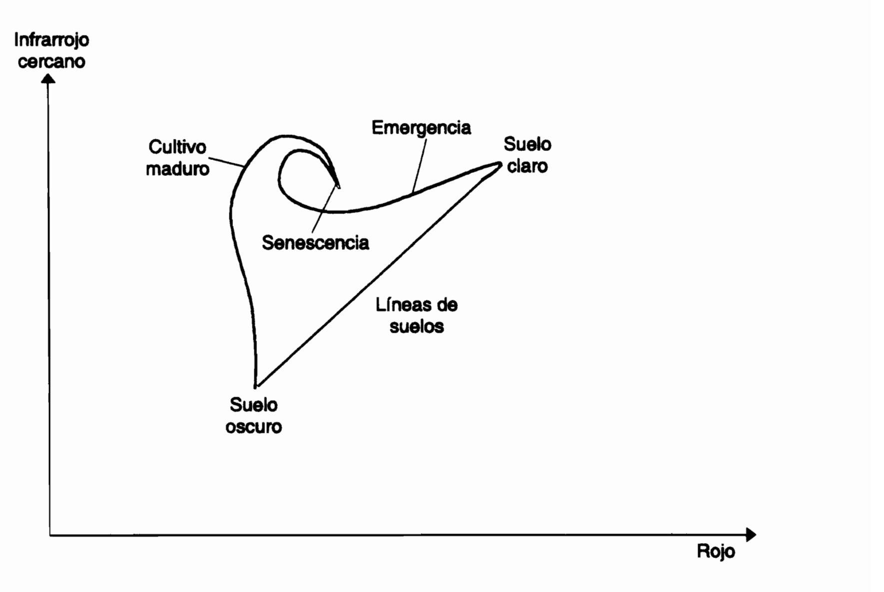


FIG. 7.13. *Evolución temporal de la vegetación en las bandas IRC y R, según el fundamento de la transformación* Tasseled Cap.

tendía relacionarse con la reducción en el vigor vegetal, y un cuarto sin significado aparente *(nonsuch)*.

En un primer momento, esta transformación no tuvo mucho eco en la literatura científica, frente a otros índices y transformaciones. En los años ochenta, sin embargo, se empleó con mayor profusión. Crist y Cicone realizaron diversos trabajos a partir de la TTC, mostrando su aplicabilidad a otros sensores, principalmente al TM y AVHRR (Cicone y Metzler, 1984; Crist y Cicone, 1984; Crist y Cicone, 1984). Para el caso del sensor TM, la tabla 7.4 recoge los coeficientes propuestos por Crist y Cicone (1984) para derivar los tres principales ejes de la TTC.

En trabajos comparativos sobre la aplicación de la TTC a imágenes MSS y TM, se ha puesto de manifiesto la presencia —en el caso de este último sensor— de un nuevo componente, denominado Humedad *(Wetness)*, estrechamente relacionado con la información que el TM proporciona del SWIR y que resulta original frente al sensor MSS. En consecuencia, una imagen TM presenta tres ejes principales de variación:

1. Brillo *(Brightness)*, que refleja los cambios en la reflectividad total de la escena. Como puede apreciarse en la tabla 7.4 se trata de una suma ponderada de todos los canales, excluido el térmico.
2. Verdor *(Greenness)*, que indica el contraste entre las bandas visibles y el IRC. Destaca la intervención de la banda 4, la ponderación negativa de las visibles y la anulación mutua de las dos en el infrarrojo-medio.
3. Humedad *(Wetness)*, que se relaciona con el contenido de agua en la vegetación y en el suelo, y se marca por el contraste entre el SWIR, en donde se manifiesta con mayor claridad la absorción del agua, y el resto de las bandas. Otros autores han propuesto denominar a este componente *Maturity* puesto que se ha encontra-

TABLA 7.4. *Coeficientes propuestos para la obtención de la TTC a partir de una imagen Landsat-TM (Crist y Cicone, 1984b)*

	B1	*B2*	*B3*	*B4*	*B5*	*B7*
Brillo	0,3037	0,2793	0,4743	0,5585	0,5082	0,1863
Verdor	–0,2848	–0,2435	–0,5436	0,7243	–0,0840	–0,1800
Humedad	0,1509	0,1973	0,3279	0,3406	–0,7112	–0,4512

do una clara relación entre él y la madurez de la cubierta vegetal. Por ejemplo, en un inventario forestal desarrollado en Oregon, se obtuvieron muy buenas correlaciones entre este componente y algunas variables forestales medidas en el terreno, siendo un magnífico indicador de la edad y densidad de la cobertura forestal. Además se observó que era el componente menos afectado por la topografía (Cohen y Spies, 1992).

La combinación de estos ejes, permite distinguir varios planos de variación (fig. 7.14), de gran interés para el estudio detallado de suelos y vegetación. En este sentido, suelen distinguirse tres planos: el de vegetación, formado por el eje de brillo y de verdor, el de suelos, formado por el brillo y la humedad, y el de transición, formado por la humedad y el verdor (Crist y Cicone, 1984).

Una de las ventajas de esta transformación frente al ACP radica en su interpretabilidad física. En efecto, los componentes deducidos a partir de la TTC tienen un significado preciso, independiente de las condiciones de la escena, puesto que se apoyan sobre las características del sensor y no sobre la radiometría de la imagen. Por tanto, los coeficientes propuestos pueden aplicarse a distintas imágenes del mismo sensor, con las salvedades propias de considerar que fueron extraídos a partir de los rasgos agrícolas del medio oeste americano.

La TTC cuenta ya con un importante rango de aplicaciones (Cicone y Metzler, 1984; Crist y Cicone, 1984; García *et al.*, 1986; Perry y Lautenschlager, 1984). De modo esporádico se ha utilizado para la corrección atmosférica (Labuto, 1991) y para homogeneizar radiométricamente una serie multitemporal de imágenes (Hall *et al.*, 1991).

Hemos aplicado los coeficientes propuestos por Crist y Cicone a la imagen Torre100 para derivar los componentes de la TTC (fig. 7.15). El primero de los componentes deducidos, conocido como Brillo, aparece como una imagen pancromática, por cuanto se trata de una combinación ponderada de las diferentes bandas. En este sentido, presenta rasgos muy similares al primer componente del ACP. El componente de Verdor, refleja con gran claridad los dominios vegetales presentes en la imagen. Destaca el contraste entre los espacios edificados y suelos desnudos frente a las cubiertas vegetales, principalmente en los cultivos y el pastizal, aunque también resultan evidentes las urbanizaciones ajardinadas. Los tonos más oscuros aparecen en suelos descubiertos, áreas edificadas y vías de comunicación (nacional de Burgos, carretera de Colmenar, Manzanares-Soto). Por último, el componente de Humedad manifiesta con claridad los cursos y láminas de agua, así como algunos sectores de vegetación con sombra y núcleos residenciales. Los tonos más oscuros se presentan en los suelos descubiertos.

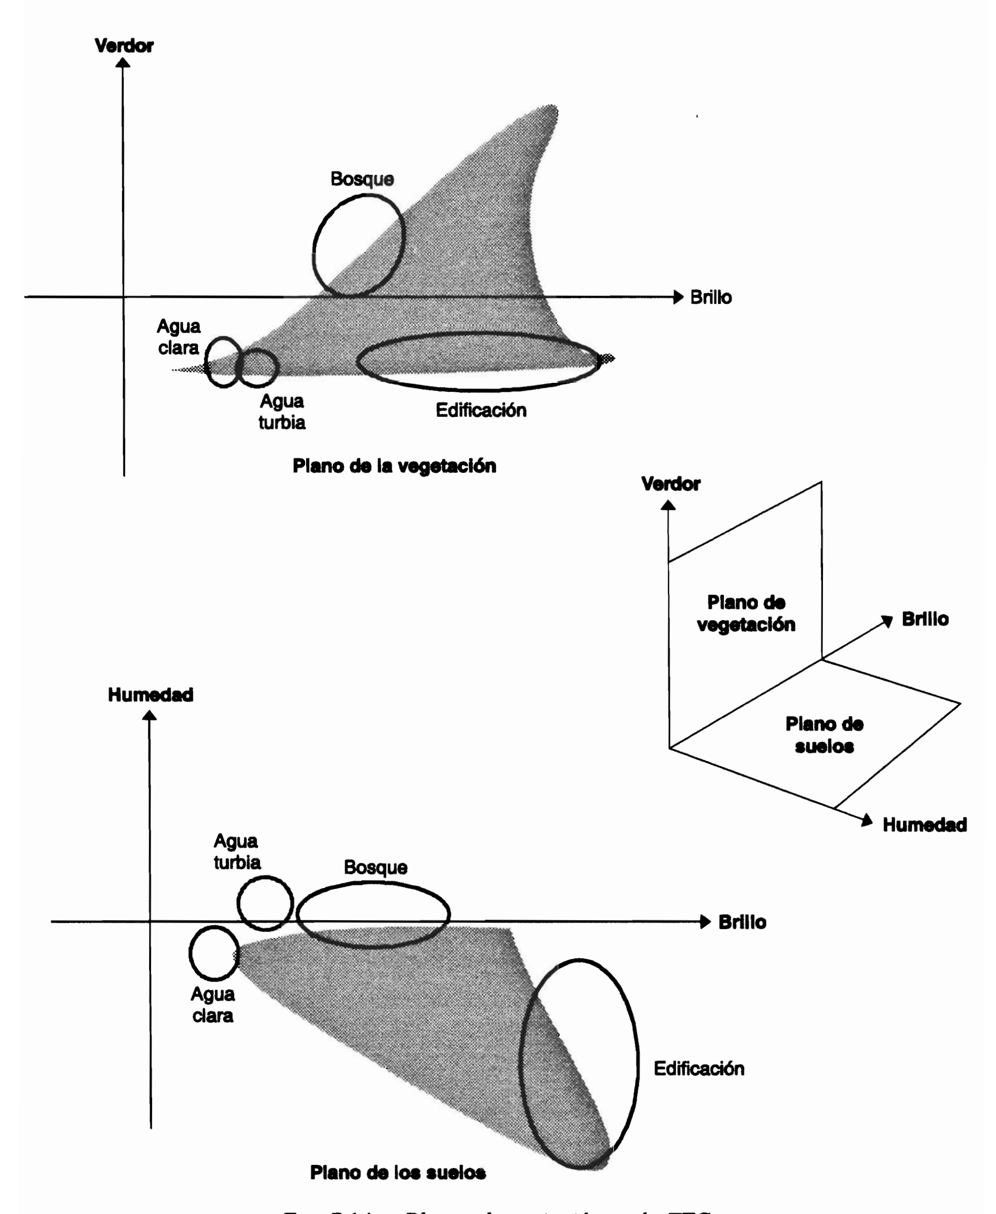


FIG. 7.14. *Planos de variación en la TTC.*

1.5. TRANSFORMACIÓN IHS

En el capítulo anterior vimos los fundamentos de la formación del color en un sistema de ADI, indicando que estas composiciones se basan en la mezcla de tres cañones de color elementales: rojo, verde y azul (RVA). Una forma alternativa de representar el color hace referencia no a sus componentes sino a sus propiedades. Se

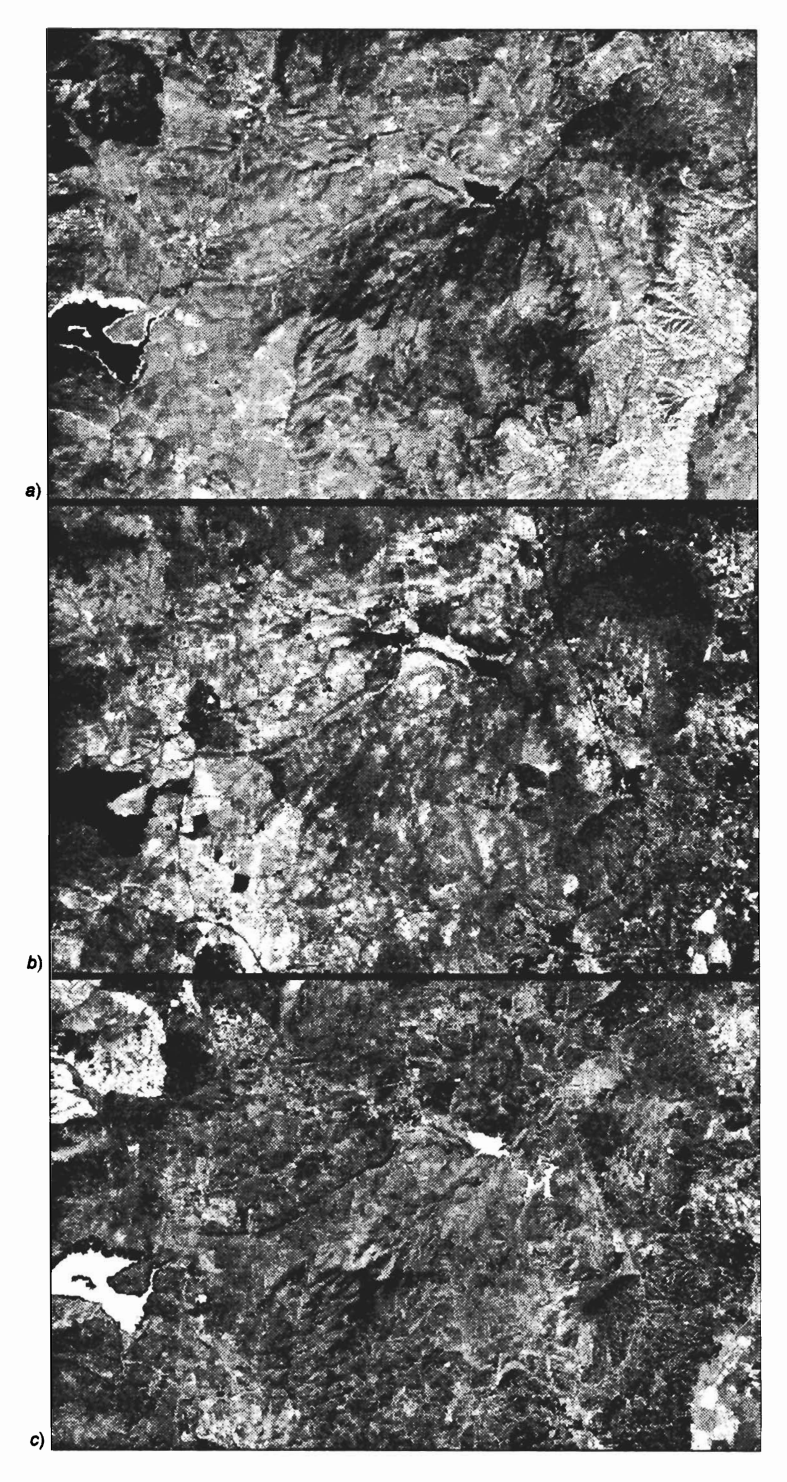


FIG. 7.15. *Componentes TTC de la imagen Torre100: (a) Brillo; (b) Verdor; (c) Humedad.*

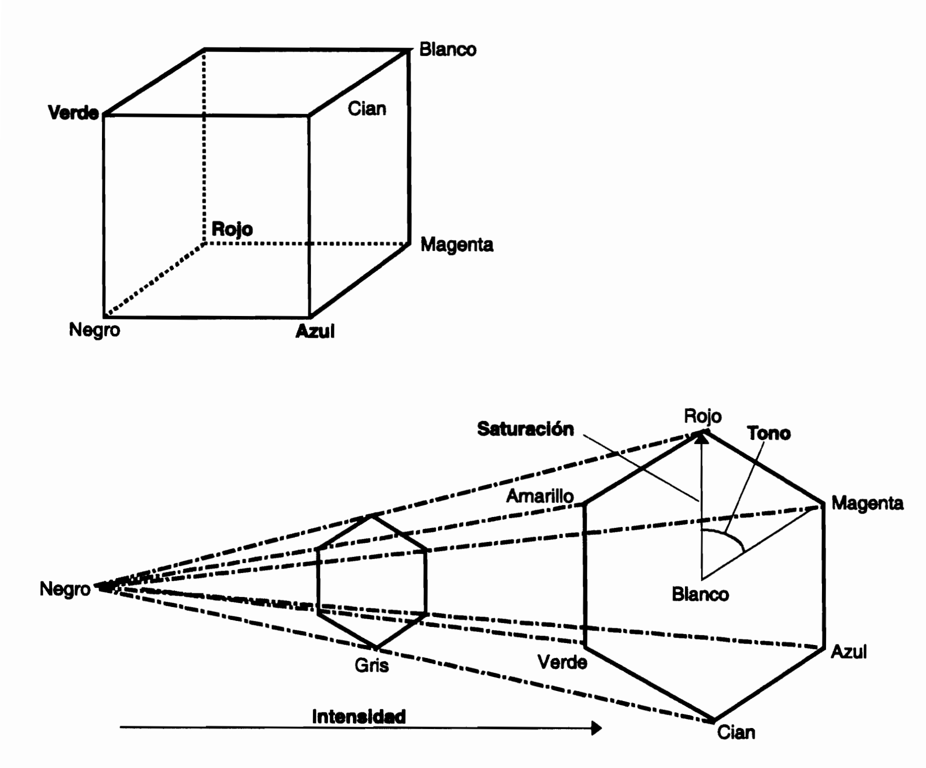


FIG. 7.16. *Representación gráfica del color a partir de las coordenadas RGB e IHS.*

trata de la transformación Intensidad, Tono, Saturación (IHS, *Intensity, Hue, Saturation*), de reciente empleo en teledetección, pero que ya ha mostrado su interés para mejorar la discriminación de algunos rasgos de marcado carácter cromático (Koutsias *et al.*, 2000; Terhalle y Bodechtel, 1986) y para combinar imágenes adquiridas por distintos sensores, como luego veremos.

El tono procede de la longitud de onda en donde se produce la máxima reflectividad del objeto: equivale al color que aprecian nuestros ojos. La saturación refiere a la pureza de dicho color, su grado de mezcla con los otros colores primarios. Por último, la intensidad puede identificarse con el brillo, en función del porcentaje de reflectividad recibido.

Es posible transformar las coordenadas de la imagen de los colores primarios (RVA) a las propiedades del color (IHS). En el primer caso, cada píxel puede representarse en un diagrama tridimensional (cada eje define uno de los colores primarios). En el segundo, por un hexácono, en donde la cara hexagonal sería el tono, el eje vertical la saturación, y la distancia al eje vertical la intensidad (fig 7.16). La transformación entre coordenadas RVA y IHS puede abordarse gracias a distintos algoritmos de conversión (Pellemans *et al.*, 1993). En primer lugar es necesario partir de una combinación de bandas determinada, que se convertirá a las coordenadas IHS. Denominaremos ND_r, ND_v y ND_a a los ND asignados al rojo, verde y azul, respectivamente. A partir de ellos se calcula la Intensidad (I) como la media de los tres:

$$I = \frac{ND_r + ND_v + ND_a}{3} \qquad \{7.18\}$$

El tono se calcula como:

$$T = \arctan\left(\frac{2\,ND_a - ND_v + ND_r}{\sqrt{3}(ND_v - ND_r)}\right) + C \qquad \{7.19\}$$

donde:

$$C = 0, \text{ si } ND_v \geq ND_r$$
$$C = \pi, \text{ si } ND_v < ND_r$$

y la saturación como:

$$S = \frac{\sqrt{6}}{3}\sqrt{ND_a^2 + ND_v^2 + ND_r^2 - ND_a\,ND_v - ND_a\,ND_r - ND_v\,ND_r} \qquad \{7.20\}$$

Como ya comentamos, la transformación IHS ha sido bastante utilizada con fines geológicos. Por ejemplo, Terhalle y Bodechtel (1986) ilustran el uso de esta transformación para la cartografía de rasgos morfológicos en zonas áridas. También se ha empleado con éxito en la determinación de áreas quemadas, gracias al muy bajo contraste cromático que presenta la vegetación quemada frente a otras cubiertas terrestres (Koutsias, 2000, #2860) (fig. 7.17). Sin embargo, donde mas aplicación ha tenido esta técnica es la referida a la fusión de imágenes de distintos sensores. Para facilitar una exposición más ordenada, dejaremos este comentario para el epígrafe dedicado a este tipo de técnicas (7.1.7).

Un ejemplo de transformación IHS puede analizarse en la figura 7.18 correspondiente a nuestra imagen de ejemplo. La composición original corresponde a un falso color mejorado (ETM+ 4/5/3, RVA), a partir del cual se han generado los tres componentes físicos: Tono, Saturación e Intensidad. La imagen de Intensidad ofrece un aspecto similar al componente de brillo de la TTC, al mostrar las tendencias promedio en las tres bandas más importantes del sensor ETM+. El Tono ofrece los valores más altos para la superficie urbana y el agua, lo que indica que el color dominante de la imagen original corresponde a las superficies más reflectivas en las bandas 3 y 5. La correspondiente a Saturación muestra también valores altos para el agua, mientras la ciudad y suelos desnudos aparecen en grises oscuros o negros. La vegetación ofrece valores altos en este componente, como consecuencia de su clara cromaticidad.

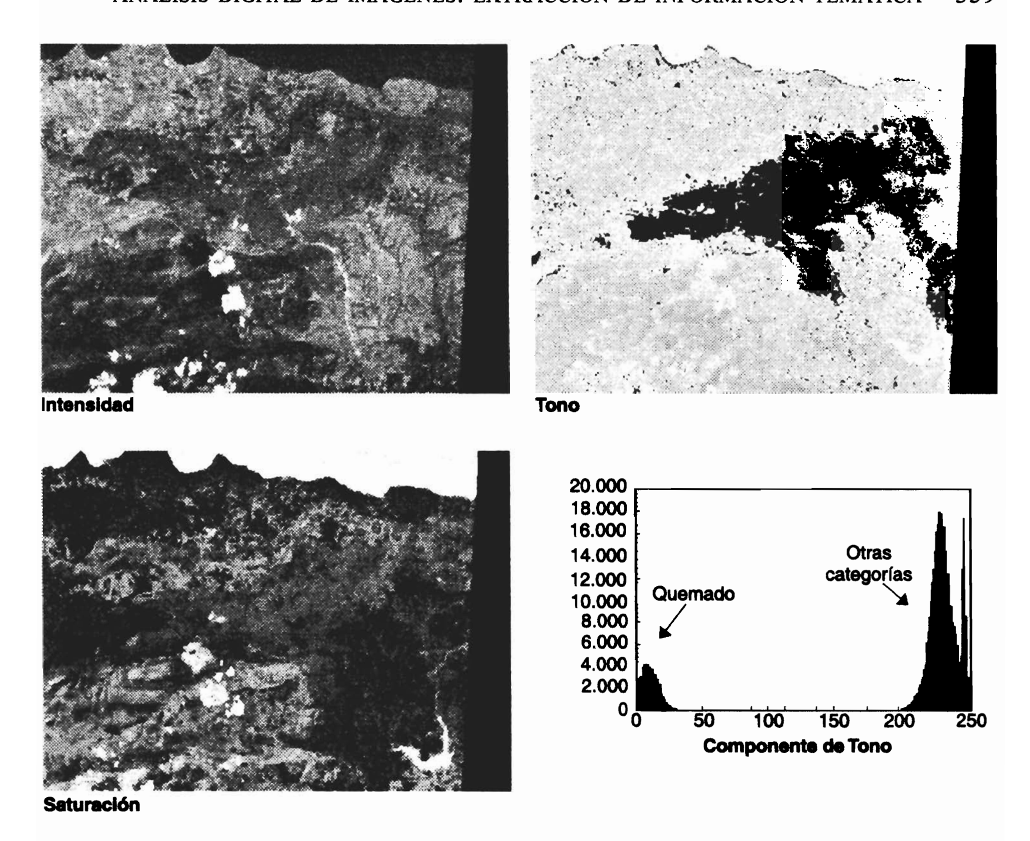


FIG. 7.17. *Empleo de la transformación IHS para discriminar áreas quemadas (adaptado de Koutsias* et al.*, 2000).*

1.6. TÉCNICAS DE ANÁLISIS HIPERESPECTRAL

Como ya vimos en el capítulo 3, la resolución espectral de los sensores espaciales había estado severamente restringida hasta hace muy pocos años, cuando se han comenzado a lanzar al espacio los primeros sensores hiperspectrales. Hasta entonces, las técnicas de tratamiento de este tipo de datos estaban restringidas a las imágenes adquiridas por sensores aeroportados, y más en concreto por el AVIRIS *(Airborne Visible/Infrared Imaging Spectrometer)*, sin duda el sensor hiperespectral que ha supuesto un mayor avance en esta disciplina. El lanzamiento del MODIS en 1999, y del Hyperion, en 2000, han abierto las puertas al empleo de estas técnicas a partir de teledetección espacial, a los que han seguido en los últimos años el MERISl, a bordo del Envisat, y el CHRIS-PROBA, ambos de la Agencia Espacial Europea.

Lo que caracteriza a este tipo de sensores, como su propio nombre indica, es su muy alta resolución espectral, que les permite adquirir un espectro bastante continuo de cualquier píxel observado (fig. 7.19). Además del notable incremento de los datos a procesar que esto implica, esa detallada definición de cada píxel nos permi-

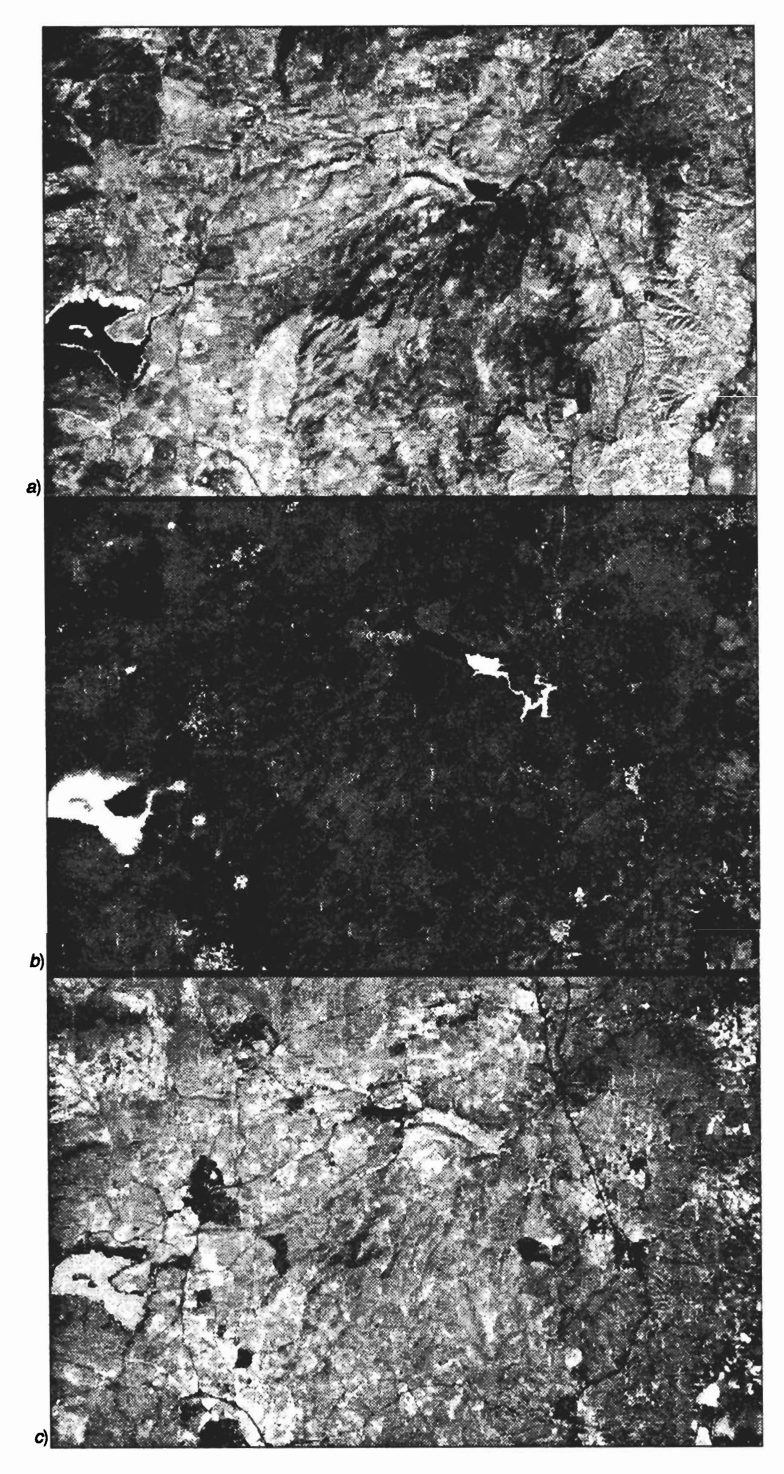


FIG. 7.18. *Componentes IHS de la imagen Torre100: (a) Intensidad; (b) Tono; (c) Saturación*

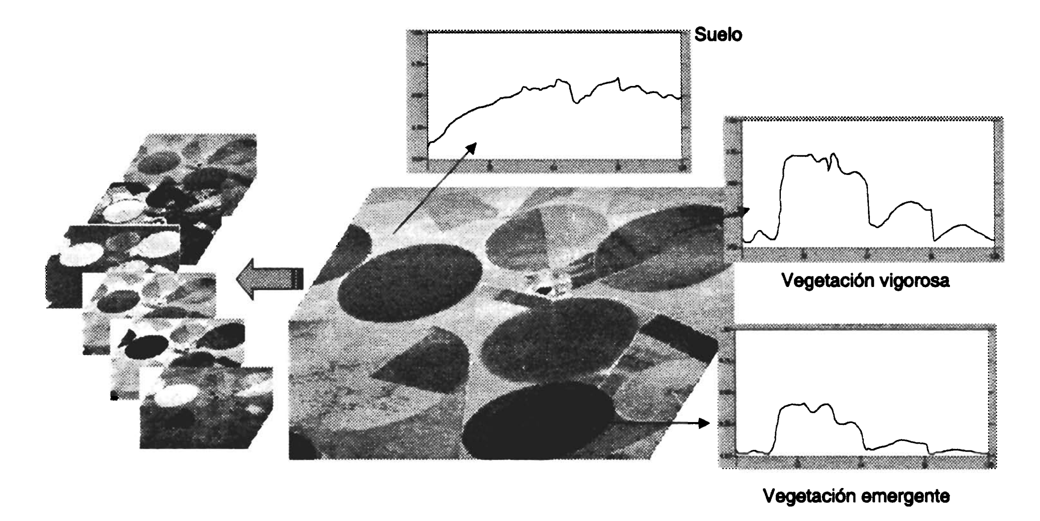


FIG. 7.19. *Concepto de imágenes hiperspectrales.*

te introducir tratamientos bastante específicos a partir de estas imágenes, que no serían abordables si contáramos sólo con unas pocas bandas. Por esta razón, nos ha parecido conveniente dedicarle un epígrafe propio dentro de esta obra, si bien algunas de las técnicas presentadas, como veremos en su comentario, podrían también emplearse en sensores más convencionales.

1.6.1. *Análisis de espectros*

Como hemos comentado, la primera característica que define una imagen hiperespectral es la gran cantidad de bandas que contiene (habitualmente en el orden de varias decenas a centenas). Esto le permite definir, en la mayor parte de los casos, espectros continuos para cada píxel de la imagen, de forma similar a las curvas que podemos obtener con un espectro-radiómetro de laboratorio, con la diferencia de que en este caso sólo medimos un punto, mientras la imagen nos proporciona una representación bidimensional de los espectros.

En consecuencia, la forma más elemental de analizar una imagen hiperespectral sería comparar los espectros que de ella se derivan con los que podemos obtener a partir de equipos de laboratorio, o de las bibliotecas espectrales disponibles al público (2.5.5). Lógicamente, esto supone convertir previamente los ND originales en valores de reflectividad, para lo que es preciso aplicar la calibración y las correcciones atmosféricas y topográficas oportunas (6.6.2). A partir de ahí, puede identificarse la cubierta de un píxel comparando su espectro con otros de referencia, aplicando alguna técnica que permita ver a cuál es más similar. Entre los métodos disponibles, vamos a comentar dos comunes: la codificación binaria y la absorción diferencial.

La codificación binaria es una sencilla técnica que calcula, para cada banda espectral, si la reflectividad observada es mayor o menor a la reflectividad media de ese espectro, asignándole un valor 0 si es inferior y 1 si es superior. Si dos espec-

tros son similares, tenderán a presentar la misma cadencia de ceros y unos a lo largo de las distintas bandas que forman esos espectros. Por tanto, al comparar la codificación binaria de un espectro desconocido con otro de referencia que corresponda a la misma cubierta obtendríamos un elevado porcentaje de parejas 0-0 o 1-1 (Mazer, 1988 #3298). Para cuantificar la similitud entre espectros, podemos calcular un sencillo índice que denominamos índice de acuerdo espectral (IAE):

$$IAE = \frac{\sum_{k=1,m}(CB_{i,k} - CB_{j,k})^2}{m} \qquad \{7.21\}$$

donde $CB_{i,k}$ indica la codificación binaria (0/1) del espectro i (el que queremos identificar) para la banda k y $CB_{j,k}$ la codificación del espectro de referencia para la misma banda. Cuanto más cercano a 0 el IAE, los espectros serán más similares y cuanto más próximos a 1, más distintos. En la figura 7.20 pueden observarse tres espectros extraídos de una imagen hiperspectral tomada por el sensor Hymap en la zona agrícola de Barrax (Albacete) en junio de 1999. Este sensor cuenta con 128 bandas comprendidas entre 0,4 y 2,5 µm. En esta figura se incluye un espectro de vegetación vigorosa (cultivos de alfalfa en este caso), otro de suelo agrícola descubierto, y un tercero de una cubierta desconocida que nos interesa clasificar. A simple vista se observa que tiene mayores afinidades con el espectro de vegetación, pero conviene cuantificar esa similitud, además de servirnos de ejemplo para ilustrar el concepto de codificación binaria. A la derecha de los espectros, en la misma figura, se inserta la codificación correspondiente a los espectros de vegetación, suelo y píxel objetivo (el que queremos asignar). Se confirma que el patrón espectral es mucho mas similar al espectro de vegetación que al de suelo. El valor del IAE de acuerdo a la fórmula anterior para el espectro de vegetación es 0,039 y para el suelo es 0,5625, confirmándose la mayor similitud con la primera.

En la misma línea de la codificación binaria se encuentra la técnica denominada *continuum removal* (Kruse *et al.*, 1993), que podríamos traducir como análisis de absorción diferencial frente a la tendencia. Se trata de señalar en cada espectro una serie de valores culminantes, que marquen los valores máximos de reflectividad en distintos segmentos del espectro (máximos locales). Estos máximos sirven para señalar las tendencias del continuo. Estos valores se utilizan para normalizar los espectros extraídos de la imagen y/o de una biblioteca espectral de referencia dividiendo estos valores por los de la tendencia, lo que permite eliminar el efecto del albedo, reduciendo la principal fuente de variación de una imagen y centrándonos en lo que es específico de cada banda (la absorción diferencial). Comparando las bandas de absorción con las que ofrezca otro espectro de referencia podrá asignarse un determinado píxel hiperespectral a una categoría de interés. Esta técnica se ha desarrollado con bastante éxito en imágenes AVIRIS para la exploración minera (Kruse *et al.*, 1993).

Además de la longitud de onda promedio de esas bandas de absorción también es interesante analizar cuál es la intensidad de la absorción, que vendría dada por la «profundidad» o, lo que es lo mismo, la magnitud de la diferencia frente a la tendencia, así como su anchura y asimetría. Estos rasgos facilitan el análisis de un espectro desconocido, delimitando rasgos de gran interés para determinar sus propie-

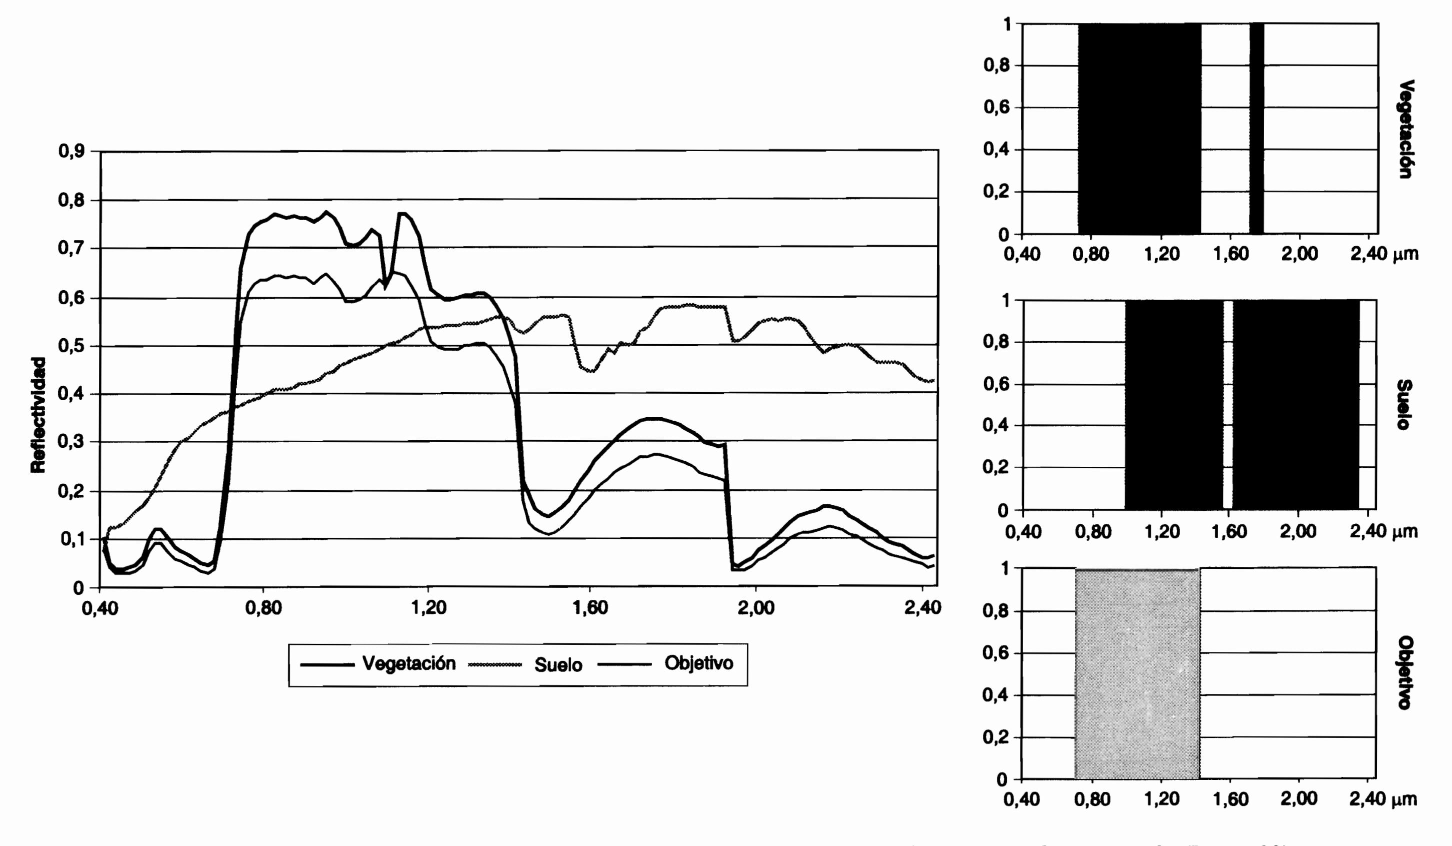


FIG. 7.20. *Codificación binaria de tres espectros extraídos de una imagen hiperespectral aeroportada (Barrax99).*

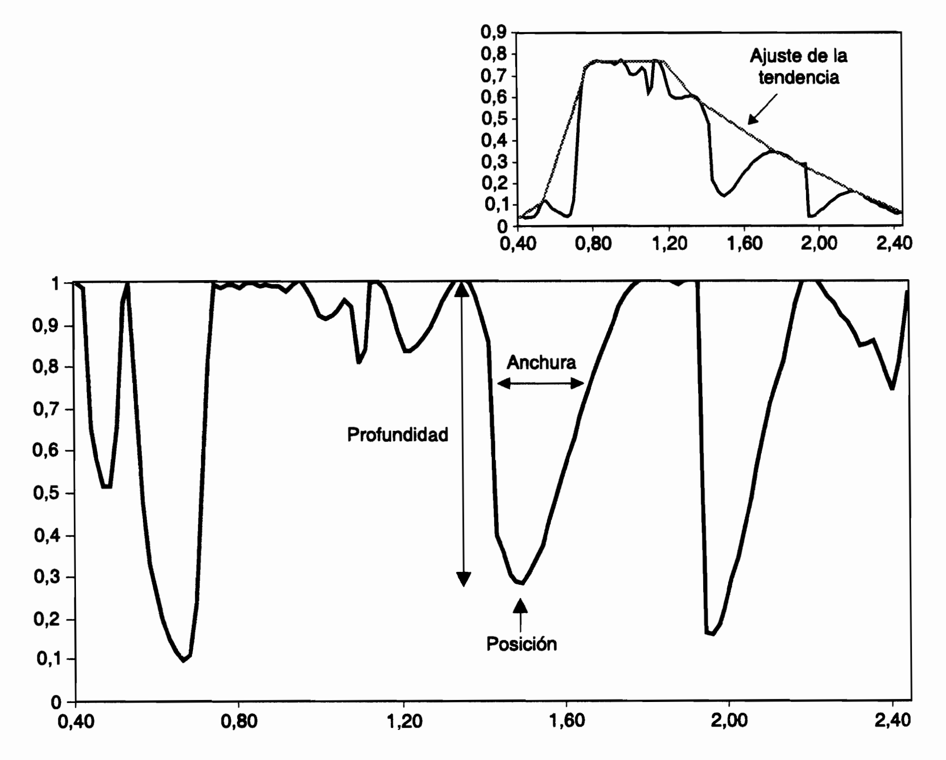


FIG. 7.21. *Ejemplo de análisis de la absorción por diferencias frente a la tendencia para el espectro de vegetación en la imagen de Barrax99.*

dades biofísicas (Tian *et al.*, 2001). La figura 7.21 incluye un ejemplo de este tipo de gráficos, para el caso específico del espectro de vegetación que hemos visto previamente. En este caso se observan una serie de bandas de clara absorción centradas principalmente en torno a 0,46, 0,65, 1,4 y 1,9 µm.

1.6.2. *Clasificación angular*

Supone otra técnica alternativa para el análisis de espectros, por lo que propiamente cabría incluirlo en el anterior epígrafe. Ahora bien, puesto que para otros autores supone una alternativa a las técnicas estadísticas de clasificación que luego comentaremos (7.2), también cabe considerarla como un apartado específico.

El clasificador angular (*Spectral Angle Mapper*, SAM) calcula la similitud entre dos espectros a partir de su desviación angular, asumiendo que forman dos vectores en un espacio n-dimensional (siendo **n** el número de bandas disponibles). En síntesis, se trata de un método para comparar espectros desconocidos con otros de referencia, ya sean tomados de la propia imagen, ya de bibliotecas espectrales. Puesto que esta técnica calcula la dirección relativa entre espectros, tiene la ventaja de ser bastante independiente de las condiciones de iluminación, ya que éstas hacen referencia a la longitud del vector pero no a su posición, y por tanto los ángulos no cambian aunque cambie el albedo.

El algoritmo determina la similitud entre dos espectros calculando el ángulo espectral que les separa (θ):

$$\theta = \arccos \frac{\sum_{k=1,m} ND_{i,k} ND_{j,k}}{\sqrt{\sum_{k=1,m} ND^2_{i,k}} \sqrt{\sum_{k=1,m} ND^2_{j,k}}} \qquad \{7.22\}$$

siendo $ND_{i,k}$ el valor del píxel i (el espectro objetivo) en una determinada banda k de la imagen, $ND_{j,k}$ el del espectro de referencia j en la misma banda, y m el número de bandas. El criterio puede utilizarse para comparar pares de espectros determinados, por ejemplo, muestras de suelos con distintos contenidos de materia orgánica, o para asignar un píxel desconocido a una clase de referencia en una clasificación temática. En este caso, el píxel i se asignará a la clase de referencia j con el valor θ más pequeño. Lógicamente, también pueden compararse los cosenos entre vectores, eliminando en la fórmula anterior la necesidad de calcular el arcoseno. Lo habitual para imágenes hiperespectrales es trabajar con valores de reflectividad, pero hemos indicado en su lugar ND ya que éstos pueden estar escalados de la forma que estime oportuno el intérprete, siempre que, como es lógico, tengan la misma métrica los de referencia y los que se pretenden clasificar.

La figura 7.22 presenta un esquema del clasificador angular, para un caso sencillo de tres bandas. Aunque se ha desarrollado en el marco del análisis hiperespectral, esta técnica también puede aplicarse a un menor número de bandas, siendo una alternativa a los clasificadores convencionales, que luego comentaremos. También el SAM puede utilizarse como técnica de inversión para calcular el espectro más similar al observado entre una serie de espectros simulados con modelos RTM. Con este enfoque se han observado resultados muy interesantes en el ámbito de la esti-

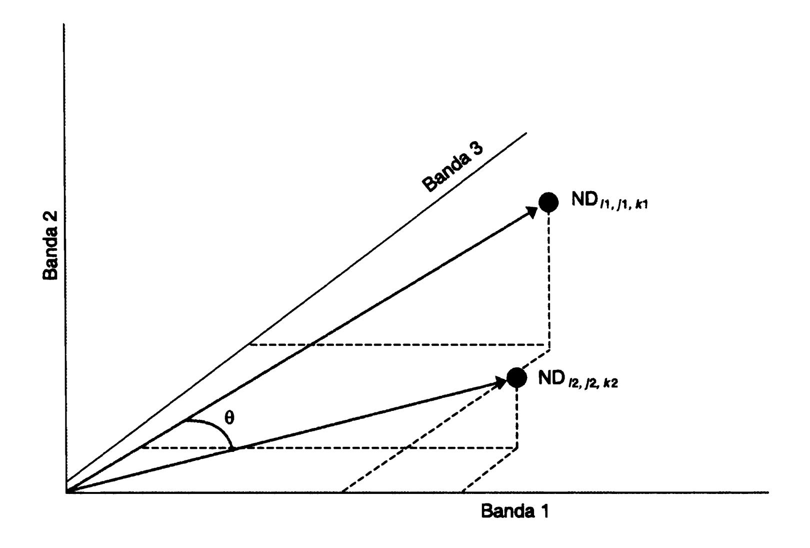


FIG. 7.22. *Esquema del clasificador angular.*

mación de la severidad de los incendios forestales (Chuvieco *et al.*, 2007; De Santis y Chuvieco, 2007).

1.6.3. *Reducción de la dimensionalidad de la imagen*

Contar con un amplio número de bandas, no cabe duda, tiene un gran interés, pero también lleva consigo una serie de dificultades, tanto en lo que se refiere al almacenamiento y proceso de la información, como a posibles problemas estadísticos que surgen cuando las variables analizadas tienen una alta correlación entre sí (Mather, 1998). Para paliar estos dos problemas (almacenamiento y redundancia), se recomienda con frecuencia utilizar alguna técnica de compactación de datos, que permita retener la mayor parte de la información original en un menor número de bandas. Con esta finalidad se utilizan varias técnicas, que pretenden retener la información más significativa contenida en la imagen hiperespectral.

Una de las más conocidas está basada en el análisis de componentes principales (ACP), que comentamos anteriormente. Se denomina Fracción de Mínimo Ruido (MNF, *Minimum Noise Fraction*), y consiste en aplicar dos ACP consecutivos: el primero, basado sobre una estimación de la matriz de covarianza residual, permite eliminar redundancias y re-escalar el ruido de los datos; el segundo, es un ACP convencional de los datos ya depurados. El ruido se estima a partir de los componentes más marginales de los autovalores, centrando el análisis en aquellos que retienen la mayor parte de la información original. (Green *et al.*, 1988).

Otra técnica de reducción del ruido en imágenes hiperespectrales es la denominada análisis en primer y segundo plano (FBA, *Foreground/Background Analysis*), en donde los espectros se dividen en dos grupos (primer y segundo plano). En el primer plano se coloca la información que nos interesa realzar y se proyecta en el eje de unos, mientras la información de menor interés se proyecta sobre ceros. De esta forma, se recogen las principales fuentes de variación en las características que pretenden medirse. Se proyectan estos dos grupos de tal manera que se maximicen las diferencias entre ellos, minimizando la diferencia en el interior de los grupos. Esto se hace definiendo un vector de pesos para cada banda que tienda a equiparar a 1 los espectros del primer plano y a 0 los del segundo. La técnica se utilizó con éxito para estimar algunas variables biofísicas de las hojas a partir de espectros de laboratorio para distintas especies vegetales (Pinzón *et al.*, 1998).

1.6.4. *Análisis lineal de mezclas espectrales*

El análisis lineal de mezclas espectrales (ALME, *Spectral Mixture Analysis* SMA) parte de asumir que la señal captada para un determinado píxel puede ser una mezcla de las reflectividades procedentes de varias cubiertas, en función de la superficie que ocupan en ese píxel, y pretende obtener precisamente esas proporciones. Por tanto, como fruto de esta técnica obtendremos tantas imágenes de salida como categorías pretendan estudiarse. En cada una de ellas, el ND de un determinado píxel indicará el porcentaje de superficie que ocupa esa categoría (fig. 7.23).

Tradicionalmente la clasificación de imágenes de satélite ha tenido por misión asignar cada píxel a una, y sólo una, de las categorías previamente definidas en la

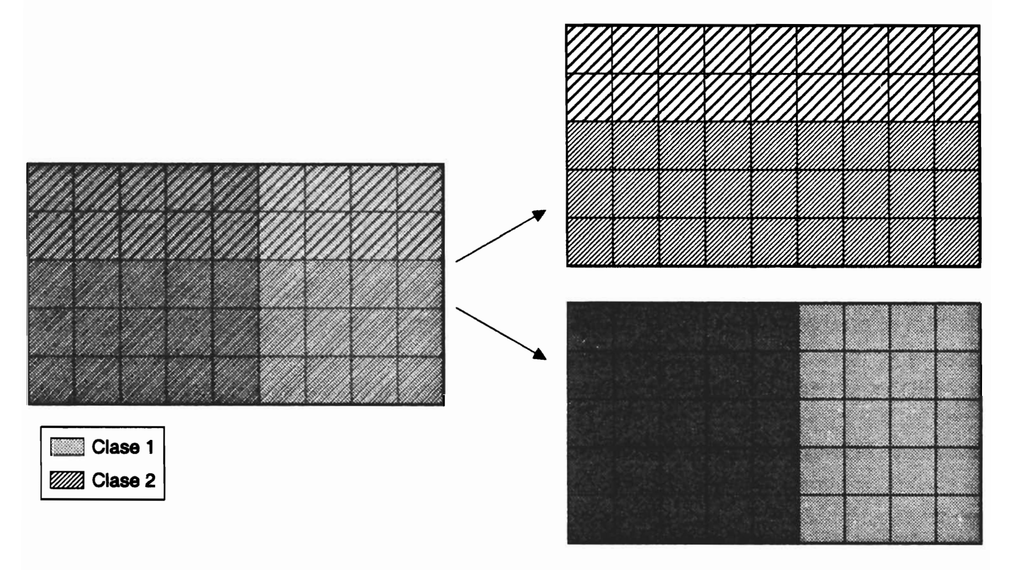


FIG. 7.23. *El ALME pretende extraer las proporciones presentes en cada píxel de unas determinadas categorías o componentes puros.*

leyenda de trabajo. Con ser de gran interés este planteamiento, como veremos en el próximo apartado, resulta un enfoque algo limitado para ciertas aplicaciones. La necesidad de categorizar cada píxel de la imagen con un código exclusivo implica asumir que ese píxel es homogéneo o, dicho de otra forma, que toda su superficie está cubierta por la categoría a la que se ha asignado. En definitiva, esa clasificación de la imagen no considera que la radiancia proveniente de un píxel, en la mayor parte de las ocasiones, es una mezcla de distintas cubiertas, y que al clasificarlo simplemente optamos por asignarlo a la cubierta dominante. A efectos de la representación cartográfica convencional, éste es el objetivo habitual, ya que los mapas temáticos asumen que cada unidad es homogénea: una misma parcela no puede asignarse a dos o más categorías. Cuando en realidad existe esa mezcla, que va más allá de la mínima unidad cartografiable a una determinada escala, las opciones más empleadas son, o bien simplificar la realidad, prescindiendo de las categorías menos representativas, o bien generar categorías mixtas, en donde la realidad se etiqueta considerando esa difícil separación en componentes. Las denominaciones «mosaico de cultivos» o «matorral arbolado» son ejemplos de este segundo enfoque.

Una alternativa a ambos planteamientos es emplear técnicas que permitan extraer información sobre el grado de mezcla presente en cada píxel. En otras palabras, se trataría de obtener imágenes que nos indiquen la proporción de cada categoría de interés en un píxel, asumiendo que la respuesta recibida por el sensor es, de alguna forma, una combinación de signaturas espectrales puras. La obtención de estos componentes no es una tarea reciente en teledetección, pues ya se ofrecían soluciones de gran interés en los años setenta (Marsh *et al.*, 1980). Sin embargo, a partir de los años noventa se extendió su empleo, especialmente a partir del uso masivo de imágenes de baja resolución espacial, como las proporcionadas por el AVHRR, en donde es especialmente crítico obtener información sobre la mezcla en el interior de un píxel.

El ALME parte de algunos supuestos que conviene considerar antes de analizar el gran potencial de esta técnica, pues también nos ayudarán a valorar sus limitaciones. En primer lugar, se asume que la radiación recibida por el sensor desde cada tipo de cubierta se restringe al ámbito de la parcela ocupada por ese píxel; en otras palabras, que no está influyendo en la radiación reflejada la señal procedente de una cubierta vecina (Settle y Drake, 1993). En caso de píxeles que contengan más de un tipo de cubierta, la segunda asunción considera que su radiancia global es proporcional a la superficie ocupada por cada cubierta. Esto equivale a que no exista una cubierta que tienda a, por decirlo así, «ensombrecer» al resto, provocando una ponderación superior a su propia superficie en la radiación finalmente reflejada al sensor. La linealidad de la mezcla es asumible sólo en las bandas del espectro óptico, no en el térmico, ya que la radiancia no es lineal con la temperatura. Por último, y más importante aún, se asume en el ALME que existen signaturas espectrales puras, válidas para toda la zona analizada (Quarmby *et al.*, 1992).

Si estas tres suposiciones son admisibles, podemos asumir que la reflectividad de un determinado píxel con mezcla es una combinación lineal de la reflectividad característica de unas cubiertas o componentes básicos (que denominaremos componentes puros o miembros terminales: *endmembers*), en proporción equivalente a la superficie que ocupan. En definitiva, se cumple la fórmula siguiente (Shimabukuro y Smith, 1991):

$$\rho_{i,j,k} = \sum_{m=1,p} F_{i,j,m} \rho_{m,k} + e_{i,j} \qquad \{7.23\}$$

donde $\rho_{i,j,k}$ indica la reflectividad observada en el píxel *i, j* en la banda *k*; $F_{i,j,m}$ es la proporción del componente *m* en ese píxel *i, j* para cada uno de los *p* componentes puros; $\rho_{m,k}$ corresponde a la reflectividad característica de ese componente *m* en la banda *k*, y $e_{i,j}$ es un término del error asociado a la estimación de las proporciones en cada píxel *i, j*.

Esta fórmula está sujeta a dos restricciones. Por un lado, la proporción de cada componente puro (F_m) debe estar entre 0 y 1:

$$0 \leq F_{i,j,m} \leq 1 \qquad \{7.24\}$$

esto quiere decir que no puede haber proporciones negativas, y

$$\sum_{m=1,p} 0\, F_{i,j,m} = 1 \qquad \{7.25\}$$

lo que indica que la suma de las proporciones para todas los componentes es igual a la superficie total del píxel.

La ecuación {7.23} también puede expresarse en términos de ND, en lugar de reflectividad, siempre que no se modifique la linealidad frente a la información inicialmente detectada por el sensor. El interés de presentar la fórmula en magnitudes físicas se relaciona con la primera fase, y más importante, del ALME: definir con precisión los componentes puros de los que van a obtenerse las imágenes «desmez-

cladas». Estos componentes son los tipos característicos de cubierta que explican la señal reflejada hacia el sensor. Se asume que el resto de situaciones que se presenten en la imagen son mezcla de ellas. Por ejemplo, los componentes puros podrían ser la vegetación sana, el suelo y las sombras, para un estudio de deforestación (Adams *et al.*, 1995; Holben y Shimabukuro, 1993); las plantaciones forestales vigorosas, las recientemente cortadas y las que ofrecen un proceso de regeneración, en el caso de un estudio forestal (Hlavka y Spanner, 1995); la vegetación sana, la quemada y las sombras, para una cartografía de incendios forestales (Caetano *et al.*, 1994), o los tipos de cultivo para un inventario de cosechas (Quarmby *et al.*, 1992). Los más habituales han sido los de vegetación vigorosa, suelo y sombra, si bien otros autores recomiendan añadir a estos tres básicos un cuarto correspondiente a vegetación seca o no fotosintética: (Riaño *et al.*, 2002; Roberts *et al.*, 1993).

Para obtener las reflectividades características de los miembros puros de la imagen pueden abordarse varios procedimientos que podemos dividir en dos grupos, según se utilicen los datos de la propia imagen o información externa. En el primer caso, podemos seleccionar los píxeles representativos de cada componente puro ($\rho_{m,k}$ en la fórmula anterior) a partir de varios criterios:

1. El más sencillo es seleccionarlo a partir del conocimiento del área de estudio que posea el intérprete, lo que le permite extraer de la imagen algún píxel que considere completamente homogéneo de cada componente puro. Como es lógico, esta selección es arriesgada, ya que si seleccionamos un píxel con mezcla, los resultados del ALME producirán un ruido equivalente. En caso de trabajar con imágenes de baja resolución espacial (como el AVHRR o el MODIS), localizar áreas homogéneas resulta muy complicado. Como precisamente sobre estas imágenes resulta de notable interés la aplicación de esta técnica —ya que facilita información sub-píxel que enriquece mucho las posibilidades temáticas de este sensor—, se ha propuesto en varios estudios extraer los componentes puros a partir de imágenes de alta resolución, como SPOT o TM, tomadas simultáneamente o muy cercanas en el tiempo. Previamente tienen que coregistrarse y calibrarse adecuadamente. A partir de ellas, se generan los valores característicos de cada componente puro, mediante técnicas de regresión o degradando artificialmente las imágenes de alta resolución hasta obtener el tamaño del píxel AVHRR (Caetano *et al.*, 1994; Foody y Cox, 1994; Hlavka y Spanner, 1995; Holben y Shimabukuro, 1993; Kerdiles y Grondona, 1995; Quarmby *et al.*, 1992).
2. Otros autores recomiendan extraer los datos de la imagen con un procedimiento más objetivo, que permita asegurar la calidad de las estadísticas aun con un escaso conocimiento del territorio. Entre las técnicas propuestas, tal vez la más extendida es la denominada *Pixel Purity Index* (PPI: (Boardman *et al.*, 1995). El método parte de representar la nube de puntos de una determinada imagen en un espacio n-dimensional, que se va reproyectando aleatoriamente. En cada iteración se anotan los píxeles extremos de esa nube, señalándose los más puros como aquellos que alcancen con mayor frecuencia la condición de extremos. Un ejemplo de este algoritmo puede analizarse en la figura 7.24, simplificando la representación para 2 bandas. Se van rotando aleatoriamente los ejes, y se anotan los píxeles extremos en cada rotación, señalando luego los más puntuados como los vértices del espacio que se va a desmezclar.

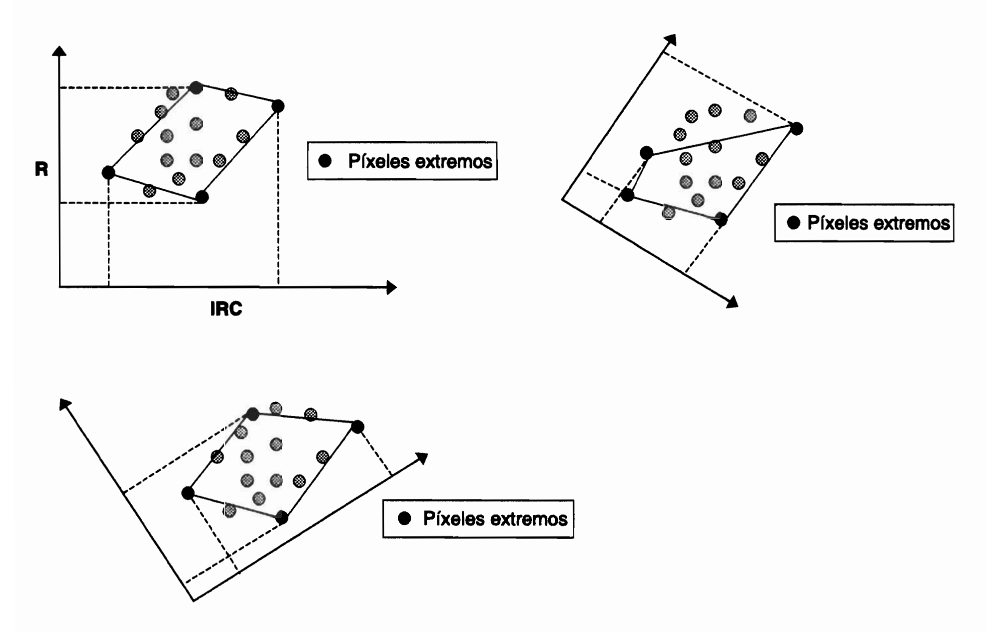


FIG. 7.24. *Fundamento del algoritmo PPI para buscar componentes puros en una imagen.*

La alternativa para extraer los componentes puros sería utilizar espectros extraídos de fuentes externas. Puede tratarse de firmas espectrales medidas con radiómetro o extraídas de alguna biblioteca espectral (ver sección 2.5.3), o incluso simuladas mediante algún modelo de simulación (ver 7.1.1). Esta opción permite controlar mejor la pureza de los valores de entrada, evitando efectos anómalos a la cubierta, como serían las condiciones topográficas o del sustrato, ya que los espectros se toman en condiciones muy controladas. Sin embargo, esta alternativa tiene otros inconvenientes, como asumir que las imágenes están adecuadamente calibradas y corregidas del efecto atmosférico y topográfico, lo que, como ya hemos visto, no resulta trivial.

Una vez obtenidas las reflectividades o ND característicos de cada componente puro, pueden generarse las imágenes de las proporciones ($F_{i,j,m}$) solucionando para cada píxel la ecuación {7.23}. Normalmente, las proporciones se obtienen de tal forma que se minimice el error residual de cada píxel ($e_{i,j,k}$). Por ello, puede reescribirse esa fórmula en función del error:

$$e_{i,j,k} = \rho_{i,j,k} - \sum_{m=1,p} F_{i,j,m} \rho_{m,k} \qquad \{7.26\}$$

de tal forma que los valores a estimar ($F_{i,j,m}$) permitan minimizar el error (o más concretamente, el cuadrado de los errores). Este es el criterio denominado de ajuste por mínimos cuadrados, que tiene dos modalidades de solución: el ajuste con restricción y el ajuste ponderado (Shimabukuro y Smith, 1991). Precisamente una de las ventajas del ALME frente a otras técnicas de interpretación es que nos ofrece una imagen de los errores del modelo en cada píxel, o dicho de otra forma, nos permite

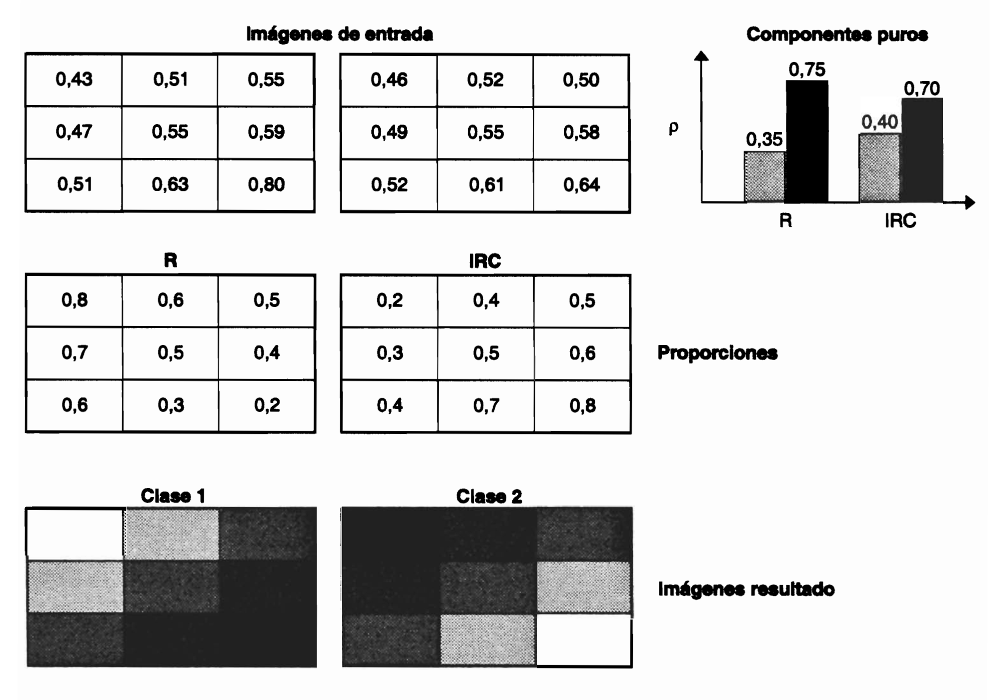


FIG. 7.25. *Ejemplo de aplicación del ALME.*

conocer el grado de ajuste de nuestro modelo a la realidad de las cubiertas presentes en cada píxel de la imagen. Si el error es alto para una determinada zona de la imagen seguramente habrá componentes puros de importancia que no se hayan identificado correctamente.

Pongamos un ejemplo muy sencillo, como es el que aparece en la figura 7.25. Se parte de los ND de dos bandas (B1 y B2) y se pretende deducir las proporciones, para cada píxel, de dos miembros puros (*c1* y *c2*), definidos por unos valores de reflectividad característica en las dos bandas (0,35 y 0,4 para la clase 1, y 0,75 y 0,7 para la clase 2). Con esos datos, deberían generarse dos imágenes de proporciones, una para cada clase de entrada. Para ello, suponiendo en el ejemplo que no existe error (esto es que las estimaciones son perfectas en cada píxel) es preciso solucionar un sencillo sistema de ecuaciones con dos incógnitas. Por ejemplo, para el primer píxel (superior, izquierda) tendríamos:

$$0{,}43 = 0{,}35\ F_1 + 0{,}75\ F_2$$

$$0{,}46 = 0{,}40\ F_1 + 0{,}70\ F_2$$

esto es, se asume que la reflectividad observada para ese píxel en las dos bandas (0,43, y 0,46) corresponde a una combinación lineal de las reflectividades de esas categorías puras, en proporción (F_1 o F_2) a la superficie que ocupan en ese píxel. Para conocer esas proporciones, basta despejar en cada una de las ecuaciones F_2 para obtener F_1:

$$(0{,}43\text{-}0{,}35\ F_1)\ /\ 0{,}75 = (0{,}46 - 0{,}40\ F_1)\ /\ 0{,}70$$

de donde se deduce que $F_1 = 0{,}8$ y, en consecuencia, que $F_2 = 0{,}2$. De igual forma se procede con el resto de los píxeles de esta imagen, obteniéndose la matriz de proporciones resultante (figura 7.25). En este caso, asumiendo que no hay error residual en la estimación de las proporciones, bastaría en realidad con una sola ecuación, ya que, si se cumplen las restricciones de no-negatividad y exhaustividad (la suma de las proporciones es igual 1) que requiere el ALME, entonces F_2 puede despejarse a partir de F_1 ($F_2 = 1 - F_1$). En suma, podríamos obtener el valor de F_1 a partir de una sola banda:

$$0{,}43 = 0{,}35\ F_1 + 0{,}75\ (1 - F_1)$$

Como es necesario contar con tantas ecuaciones como incógnitas, podemos seleccionar hasta un máximo de tantos componentes puros como bandas haya disponibles. Sin embargo, si añadimos el requisito de exhaustividad, estamos incluyendo una ecuación adicional en el problema; de ahí, que puedan incluirse hasta un máximo de $k + 1$ componentes en el ALME, siendo k el número de bandas. Esto siempre que supongamos nulo el error, de otra forma, se incluye una incógnita más (el error del ajuste para cada píxel), y habría que limitar el número de componentes al de bandas. Esta es la práctica más habitual.

Lógicamente, el ALME se aplica a situaciones más complejas que la incluida en nuestro ejemplo. En consecuencia, es preciso abordar criterios más refinados para solucionar el sistema de ecuaciones planteado anteriormente. Entre los diversos procedimientos que se han propuesto para ello, el estimador más sencillo es el ajuste por mínimos cuadrados sin restricciones. En notación matricial, este estimador se expresa como (Gong *et al.*, 1994; Settle y Drake, 1993):

$$\hat{f} = (M^T\ M)^{-1}\ M^T\ X \qquad \{7.27\}$$

donde f indica el vector con las proporciones calculadas para cada píxel, M indica el vector con los valores de los componentes puros en las bandas de análisis y X el vector con los valores del píxel en cuestión para esas mismas bandas. El superíndice T indica la transpuesta de la matriz y -1 la inversa. Este algoritmo es relativamente rápido pero no satisface las restricciones antes mencionadas. Para solucionar esto, basta con poner a cero los valores negativos de f y escalar el resto para que sumen 1. Otros criterios de solución, que incluyen directamente estas restricciones pueden consultarse en Settle y Drake (1993) y en Shimabukuro y Smith (1991). Mather (1998) apunta la importancia de que las bandas de entrada no están altamente correlacionadas; de lo contrario habrá serios problemas para invertir la matriz de entrada. Finalmente, también se han propuesto soluciones menos supervisadas, en donde los valores de los componentes puros no se conocen, lo que implica aumentar el número de incógnitas y acudir a soluciones no lineales, que se resuelven iterativamente analizando en cada paso la variación del error (Tompkins *et al.*, 1997).

El ALME resulta de gran interés para extraer información compleja de las imágenes hiperespectrales, pero no se restringe a este tipo de datos, sino que se ha

empleado en contextos muy variados. Es muy apropiada para expresar el carácter continuo de los datos ambientales, que no tienen una clara solución de continuidad en el espacio. Además implica una interesante alternativa para extraer información de los sensores de baja resolución espacial, AVHRR, MODIS o Vegetation, ya que facilita estimaciones sobre las mezclas, tan abundantes en estos píxeles de gran tamaño, manteniendo una alta frecuencia de adquisición y bajo coste. El campo más claro de aplicación es el agrícola: superficie cultivada y rendimiento, en donde el ALME ha mostrado ya excelentes resultados (Kerdiles y Grondona, 1995; Quarmby *et al.*, 1992). Asimismo, resulta un aliado clave en los estudios de deforestación (Adams *et al.*, 1995; Holben y Shimabukuro, 1993; Shimabukuro *et al.*, 1994; Souza *et al.*, 2005), para estudiar regeneración de especies vegetales (Hlavka y Spanner, 1995), densidad de cabida cubierta (Gong *et al.*, 1994), cartografía de la vegetación (Roberts *et al.*, 1998), y en el seguimiento y discriminación de áreas quemadas (Caetano *et al.*, 1996; Martín y Chuvieco, 1998; Riaño *et al.*, 2002). Además, se ha utilizado profusamente en cartografía de suelos y formaciones minerales (Adams *et al.*, 1986; Palacios-Orueta y Ustin, 1998; Smith *et al.*, 1990; Smith *et al.*, 1990).

Como ejemplo de esta transformación, hemos calculado los componentes ALME de las categorías agua, vegetación y suelo descubierto para la imagen Torre100. Para ello, hemos utilizado un programa incluido en el paquete XPACE de PCI, que incorpora un algoritmo de mínimos cuadrados con restricciones de no negatividad y exhaustividad. Los componentes calculados se incluyen en la figura 7.26 que recoge también el término de error (RMS).

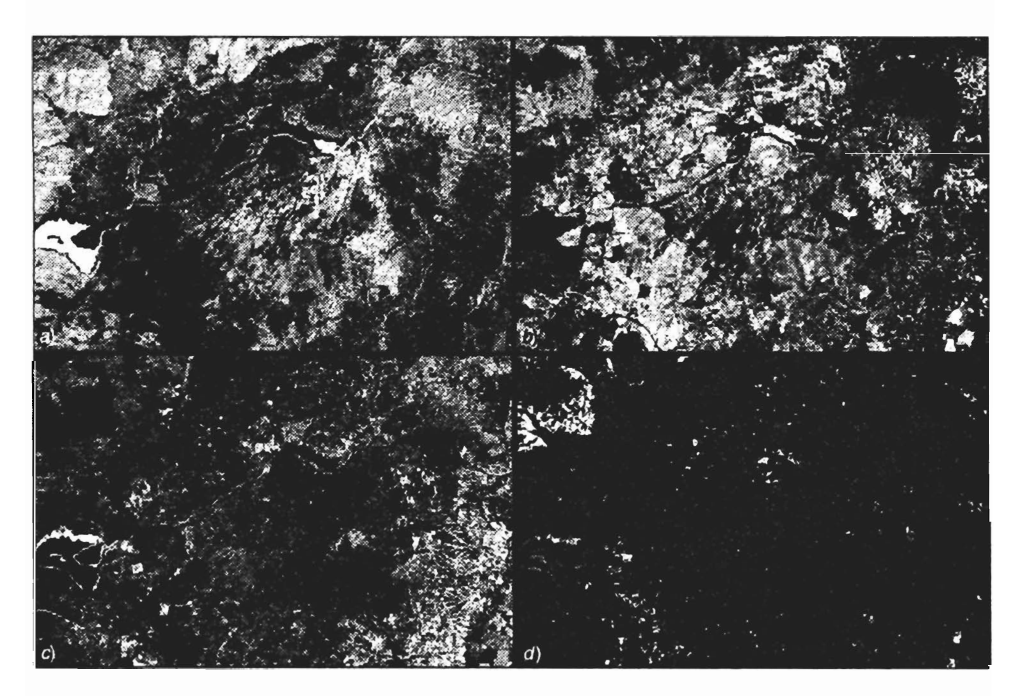


FIG. 7.26. *Componentes ALME de la imagen Torre100: (a) agua; (b) vegetación; (c) suelo; (d) RMS.*

El comentario de estas imágenes de proporciones resulta bastante análogo al que hemos realizado de los componentes principales y *tasseled cap*, ya que están reflejando las tres dimensiones básicas de información incluidas en una imagen ETM. En este caso, cada componente tiene un sentido físico: la proporción de agua, vegetación o suelo que presenta, en un continuo desde la máxima cantidad (100 %) que aparece en las zonas espectralmente más similares al componente puro, hasta las que ofrecen una proporción prácticamente despreciable. El componente de agua presenta los valores más altos en los embalses del área de estudio, así como en algunos sectores de vegetación perennifolia, que muestran una afinidad intermedia entre el agua y la vegetación herbácea vigorosa (donde se definió el componente vegetación). Precisamente estas zonas de pastizal son las más claramente recogidas en el componente vegetación, así como los cultivos herbáceos de secano, mostrando valores medios las especies perennifolias, principalmente el matorral y pinar. El suelo por su parte muestra valores más altos para las parcelas con poca o nula vegetación, así como los bordes de los embalses, cuyos márgenes estaban secos en esta época del año. Este componente es más abundante en el valle del Jarama, en el sector oriental de la imagen, donde es más frecuente la ocupación agrícola del territorio. Finalmente, el componente de error muestra un patrón bastante aceptable, con tendencia a valores bajos en toda la imagen, excepción hecha del área de pinar, en el vértice NW, que ofrece valores más elevados. Esto implica, claramente que faltó este tipo de componente (podríamos haberlo denominado vegetación perennifolia, por ejemplo) en la definición de los componentes puros ALME, lo que hubiera facilitado una delimitación más clara de este sustrato espectral.

La figura 7.27 recoge otro ejemplo de aplicación de esta técnica, en este caso a la delimitación de los espacios verdes en una zona urbana. El objetivo último de este trabajo era extraer una serie de variables de la imagen para plantear modelos de calidad de vida urbana, tomando como ejemplo la ciudad de Maracaibo en Venezuela (Molina, 1998). El ALME se empleó en este contexto para extraer las proporciones de áreas ajardinadas dentro de la ciudad, ya que se consideró que sería una variable de interés para diferenciar sectores de calidad ambiental dentro de la ciudad. La ventaja del ALME en esta aplicación es permitirnos obtener una imagen más precisa de la distribución de jardines de pequeñas dimensiones. En una clasificación convencional, únicamente se clasificarían como áreas verdes los jardines de cierto tamaño (varias veces superior al tamaño del píxel), quedando infravaloradas las masas vegetales que se presentan en las urbanizaciones de mayor calidad residencial, que no suelen ocupar grandes extensiones, o al menos no de forma homogénea, ya que estarán imbricadas con superficies construidas. Para este análisis planteamos un componente ALME relacionado con los materiales de construcción, otro con la vegetación fotosintética (estos serían los jardines), un tercero con la vegetación seca (la que no recibe un aporte de riego en verano, y por tanto se relaciona mas con la vegetación residual urbana), y finalmente el margen de error. La distribución del componente vegetación (fig. 7.25*b*) permitió obtener una imagen mucho más realista de la distribución de los espacios verdes.

El último ejemplo que recogemos en este epígrafe está extraído de una investigación sobre empleo de imágenes de satélite en el análisis de procesos de desertificación (Collado *et al.*, 2002). Hemos seleccionado la comparación temporal entre los componentes ALME correspondientes a láminas de arena para dos fechas sepa-

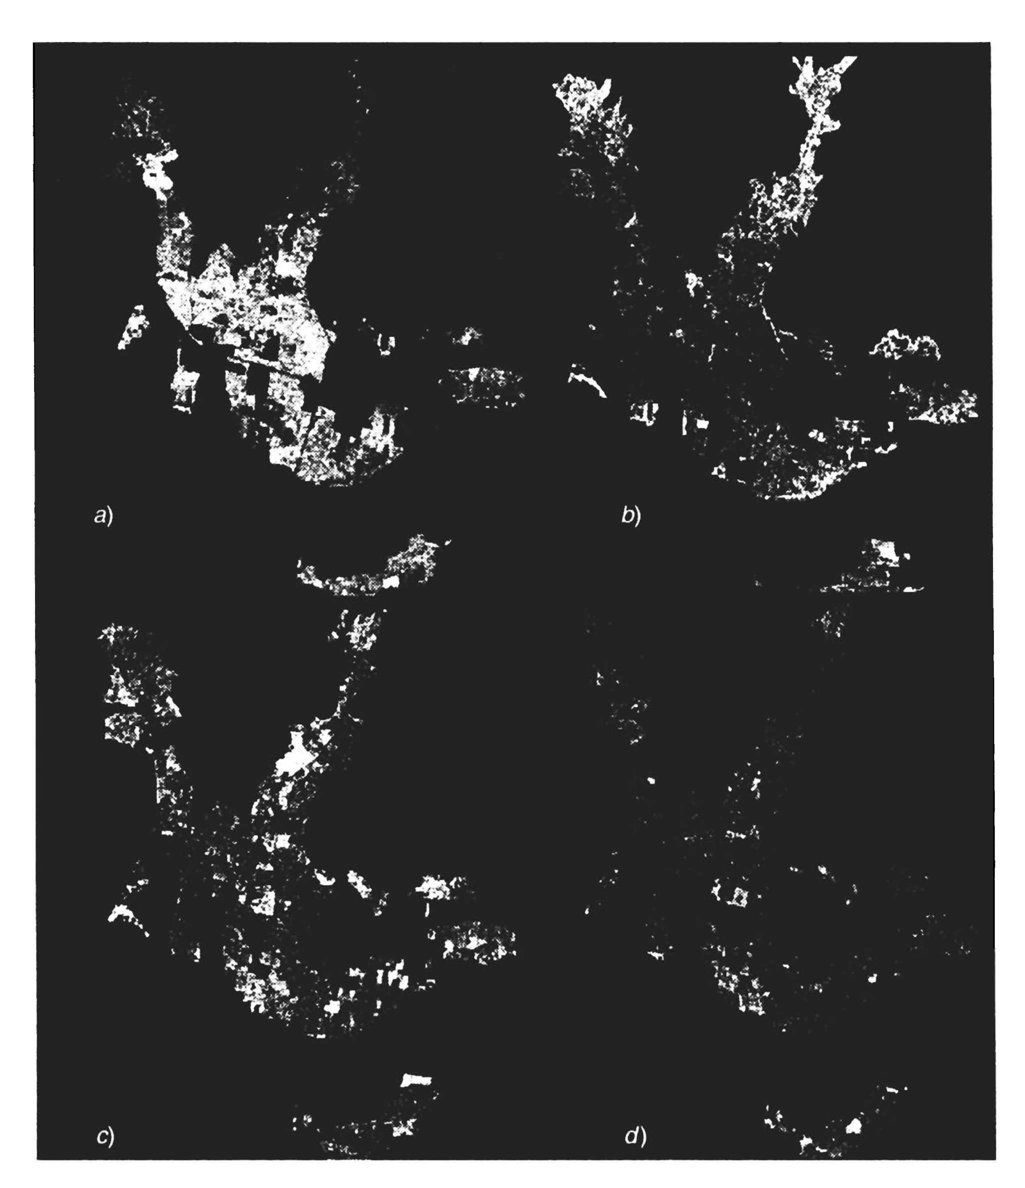


FIG. 7.27. *Componentes ALME para el sector urbano de Maracaibo (Venezuela): (*a*) materiales de construcción; (*b*) vegetación fotosintética; (*c*) vegetación seca; (*d*) RMS (Molina* et al., *1999).*

radas 10 años en un sector de la provincia de San Luis (Argentina) especialmente afectado por este fenómeno. Puede observarse en la figura 7.28 como el ALME ha permitido discriminar con bastante detalle el área cubierta por arena, y nos permite seguir la evolución de este fenómeno una vez que las dos imágenes están registradas entre sí. Una simple resta en los ND de las dos imágenes nos ofrece un análisis de tendencia muy interesante, ya que la dirección de avance de los frentes dunares está en clara relación con los patrones de vientos dominantes en la región.

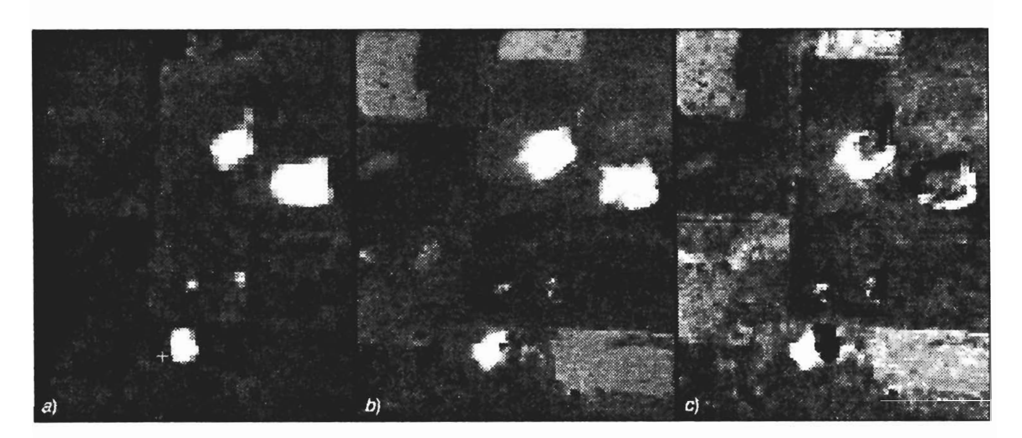


FIG. 7.28. *Componentes ALME de láminas de arena: (a) 1982; (b) 1992; (c) resta de ambas (Collado* et al., *2002).*

1.7. Técnicas de fusión de datos

1.7.1. *Enfoques en la fusión de imágenes*

Resulta patente el interés de abordar estudios de teledetección a distintas escalas y con distintos niveles de detalle para entender mejor los procesos que afectan al conjunto del planeta. Gracias a los distintos grados de resolución actualmente disponibles podemos abordar mediante imágenes de satélite un rango muy amplio de escalas: desde la local —en condiciones muy controladas, pero de escasa representatividad espacial— hasta el global, potencialmente menos fiable pero con mayor capacidad de generalización (Ehleringer y Field, 1993; Quattrochi y Goodchild, 1997).

Como es lógico, no existe ningún sensor que pueda facilitar ambos niveles de detalle simultáneamente, acercándose más a una escala local o global según las características de su diseño. El interés de poder abordar estudios a distintas escalas hace que las técnicas de integración de datos provenientes de distintos sensores se consideren cada vez con mayor atención, dando lugar a toda una nueva línea de trabajo en teledetección que recibe el nombre genérico de fusión de datos, que incluye asimismo la integración entre las imágenes de satélite y otras variables espaciales (Gong, 1994; Wald, 1999).

El objetivo último de estas técnicas es aprovechar las ventajas particulares de los datos que se ponen en relación, paliando sus defectos; por ejemplo, podrían combinarse imágenes de distintas resoluciones espaciales, temporales o que abarquen distintas bandas del espectro (radar-óptico). Éste sería el caso de generar una imagen sintética a partir de una pancromática de alta resolución espacial con una multiespectral con píxel más grosero: obtendríamos la calidad espacial de la primera con el contraste cromático de la segunda. De igual forma, podríamos integrar imágenes de satélite con mapas de temperaturas, MDE, o series de vegetación, en una clasificación integrada, de cara a mejorar la discriminación de un determinado rasgo de interés.

En pocas palabras, lo que se pretende es mejorar la interpretabilidad de los datos, ya sea mejorando su calidad visual, la facilidad para discriminar ciertas categorías, aumentar la fiabilidad de la estimación de una determinada variable, o demostrar la solidez de un determinado método de análisis.

La fusión de datos puede plantearse a distintos niveles. El más intenso llevaría a generar imágenes sintéticas, combinando información procedente de dos o más sensores para producir una sola imagen resultado; el segundo implicaría tratar información de varias fuentes en paralelo, de cara a mejorar la discriminación de un cierto rasgo de interés; similar a él también podríamos plantear la integración de los resultados obtenidos de varias fuentes independientes; finalmente, puede proponerse integrar varias versiones de los datos (imágenes sintéticas y originales, resultados de la interpretación) al nivel de la toma de decisiones (Gong, 1994).

1.7.2. *Obtención de imágenes híbridas*

De los objetivos arriba comentados, sin duda el más habitual en las técnicas de fusión de datos ha sido el que tiende a realzar el aspecto visual de una determinada imagen con información proporcionada por otra de mejor resolución espacial. Al final del proceso tendríamos una imagen sintética (multiresolución), que alberga el detalle cromático de unas bandas sobre la calidad espacial de otra.

La llegada de los sensores de muy alta resolución espacial (IKONOS, Quickbird, Cartosat, SPOT-5) ha renovado el interés de esta aplicación, ya que permite mejorar considerablemente la definición de una determinada imagen, de cara a su posterior análisis visual o integración con otros datos espaciales en el entorno de un SIG. Sin embargo, las primeras ideas para obtener este tipo de productos se remontan a los años ochenta, cuando se propusieron las primeras técnicas para fundir imágenes Landsat-MSS y RBV (Short, 1982), o incluso Landsat y fotografías aéreas digitalizadas (Iverson *et al.*, 1989). Con el lanzamiento del SPOT en 1986 se comenzaron a producir imágenes sintéticas entre sus canales pancromático (10 m) y multiespectral (20 m) (Carper *et al.*, 1990), o incluso entre el SPOT pancromático y el multiespectral Landsat-TM (30 m). Actualmente, el mercado de los productos híbridos se centra sobre todo en combinar las imágenes de sensores de muy alta resolución. Por ejemplo, el objetivo sería fusionar el IKONOS pancromático, con 1 m, con las bandas multiespectrales de ese mismo sensor, a 4 m. Para aplicaciones de escalas medias, la fusión del canal pancromático del sensor ETM+ (15 m) con los multiespectrales (30 m) también puede resultar de gran interés. La creciente disponibilidad de sensores hiperespectrales también permite ampliar este objetivo hacia fusiones de distinta naturaleza según el objetivo último de la interpretación (Robinson *et al.*, 2000).

Se han propuesto varias técnicas para obtener imágenes híbridas de dos resoluciones espaciales distintas (Tapiador y Casanova, 2001). Los dos grupos más importantes de técnicas serían las basadas en operaciones algebraicas, por un lado, y en transformaciones, por otro. En el primer caso, se integra el componente pancromático con el multiespectral empleando alguna operación de promedio, que iguale la radiometría entre las multiespectrales y la pancromática, para luego multiplicar ésta por la original. Algunos algoritmos que han sido aplicados con esta finalidad son:

1. Una integración ponderada entre el canal pancromático y el canal infrarrojo cercano:

$$M_p = \frac{2\text{Pan} + \text{ND}_{\text{irc}}}{3} \qquad \{7.28\}$$

el resultado se sustituye por el componente Intensidad (Chavez *et al.*, 1991).

2. Una suma ponderada del pancromático con los canales multiespectrales, aplicando previamente un filtro de paso alto para realzar el componente espacial de la imagen pancromática (Chavez et al., 1991).

3. Una sustitución selectiva del pancromático por las bandas espectrales verde y roja, tras aplicarle unas correcciones radiométricas para reducir las diferencias de calibración entre bandas (Pellemans et al., 1993).

El segundo grupo de los métodos de fusión incluyen una amplia lista de operaciones, desde el ACP y la transformación IHS, hasta las transformadas de Fourier y Wavelets. En este enfoque, se trata de extraer el componente espacial de la imagen multiespectral, sustituyéndolo posteriormente por la imagen pancromática, para luego retornar al espacio multiespectral original, ya con la información espacial añadida.

La más tradicional entre las fusiones transformadas ha sido la basada en la transformación IHS, por lo que podemos utilizarlo aquí para ilustrar el proceso (fig. 7.29). El primer paso, como en cualquier otra fusión, es asegurar que las dos imágenes (pancromática y multiespectral) tengan el mismo tamaño de píxel y se refieran a la misma posición en el espacio. Esto implica una previa georreferenciación de esas dos imágenes, o al menos un ajuste relativo entre ellas. En ese paso, el píxel de la imagen multiespectral debe ampliarse hasta el tamaño del píxel de la pan-

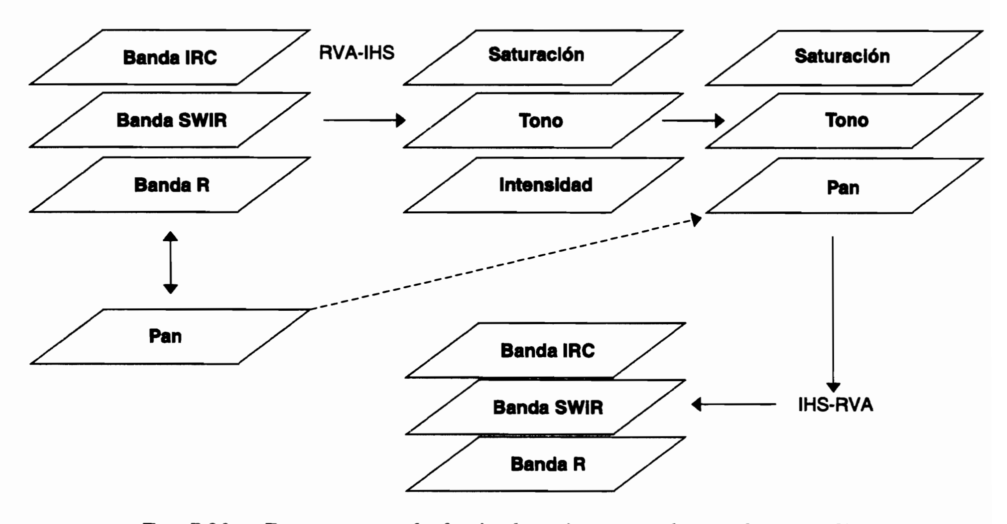


FIG. 7.29. *Esquema para la fusión de imágenes mediante algoritmo IHS.*

cromática (reduplicando el valor de sus ND), lo que garantizará que puedan superponerse adecuadamente. A continuación se selecciona la composición en color sobre la que quiera basarse la fusión. Esta composición estará expreada en coordenadas RVA, como es habitual. Se transforma al espacio IHS, tal y como vimos previamente (7.1.5). El tono y la saturación refieren al contenido espectral de la imagen, mientras la intensidad se relaciona con las variaciones espaciales del albedo, que están más en relación con las características espaciales de la imagen. En consecuencia, este componente tenderá a presentar una buena correlación con la imagen pancromática (fig. 7.30). Por tanto, podemos sustituir una por otra, de tal forma que se incorpore el detalle espacial de la pancromática sin afectar a la tonalidad de la composición en color original. Por último, se aplica la transformación inversa, de componentes IHS a RVA, obteniéndose un producto visual muy mejorado (fig. 14*).

Este proceso resulta adecuado en muchas aplicaciones, pero puede ofrecer pobres resultados si el rango espectral de la pancromática no se ajusta bien al correspondiente a las tres bandas que se mezclan en la composición RVA. De hecho, se comprobó hace unos años que el componente Intensidad de una composición SPOT no estaba bien correlacionado con el pancromático (Chavez *et al.*, 1991; Pellemans *et al.*, 1993). Más recientemente se han propuesto métodos provenientes del mundo de la cartografía, que subrayan la diferente importancia de las variables visuales en la representación de imágenes. Este es el caso de un método propuesto por el centro canadiense de teledetección que permite integrar imágenes radar, MDE e imágenes ópticas, utilizando una variante del método IHS para reforzar la visualización de rasgos tridimensionales (Toutin *et al.*, 1998). También son recientes las aplicaciones de la transformación de «onditas» *(Wavelets)* en el dominio de las frecuencias, para obtener imágenes híbridas con dos resoluciones distintas (Garguet-Duport, 1997; Yocky, 1996), y el empleo de técnicas estadísticas para maximizar la información extraíble de las imágenes utilizando el concepto de entropía (Tapiador y Casanova, 2001).

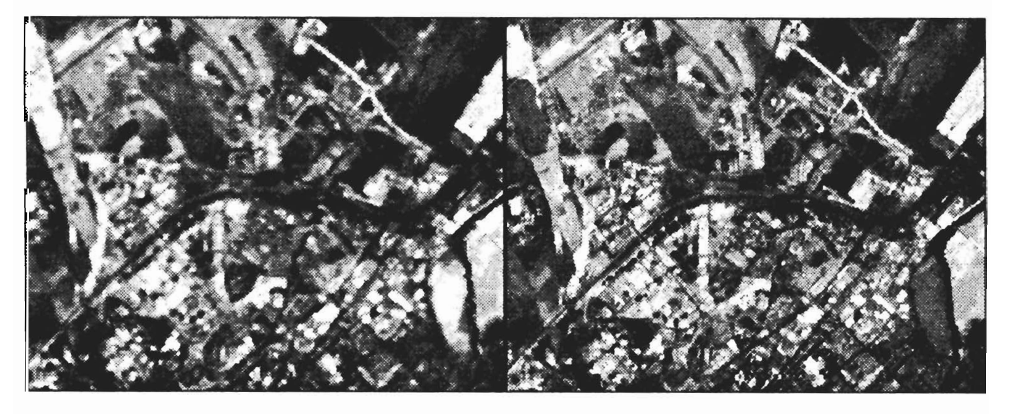


FIG. 7.30. *Imagen de la Intensidad para una composición ETM 4/5/3 (dcha.) y del canal pancromático (izda.) de una imagen sobre la ciudad de Alcalá.*

1.7.3. *Interpretación sintética con datos de distintas fuentes*

Una forma concreta de combinar información, que se ha venido aplicando casi desde el inicio de la teledetección digital, es la clasificación conjunta de datos de distintas fuentes, incluyendo no sólo imágenes de varios sensores, sino también otras variables geográficas, como pueden ser mapas de precipitación, temperatura o suelos. El desarrollo de los SIG a lo largo de los años ochenta y noventa ha reforzado esta tendencia, que luego tendremos ocasión de comentar con más detalle (cap. 9). Dejaremos para este epígrafe aquellos aspectos de la relación entre ADI y SIG que conciernen más a la integración propiamente dicha.

Utilizar datos procedentes de distintas fuentes es una alternativa interesante para mejorar la discriminación de ciertas cubiertas de interés, que pueden ser difícilmente discriminables si nos basamos exclusivamente en los datos de la imagen. Por ejemplo, para diferenciar olivar y viñedo puede ser necesario acudir a mapas de suelos para estimar la señal mixta que proporcionan, ya que esta mezcla resulta clave en la señal detectada por el sensor. En un inventario forestal, la situación topográfica (proporcionada por un MDE) o la textura (extraída de una imagen radar) puede ser crucial para distinguir distintas especies, difícilmente diferenciables de otra forma.

Naturalmente, esta integración plantea también distintos problemas, ya que se pretende analizar en conjunto datos que provienen de diversos orígenes y, por tanto, pueden ofrecer distintos niveles de detalle y escalas de medida. Como veremos en el siguiente epígrafe, la mayor parte de los métodos de clasificación digital se basan en técnicas estadísticas que no pueden aplicarse a variables categóricas, donde los individuos se diferencian sólo por pertenecer a categorías distintas sin relación numérica entre ellas (como ocurre, por ejemplo, mapas de suelos o de vegetación). En consecuencia, si quieren emplearse estas variables en la clasificación digital es necesario emplear otro tipo de técnicas, como pueden ser los clasificadores basados en criterios de decisión o en redes neuronales que luego comentaremos (7.2.3.4). El análisis de errores también se modifica notablemente cuando se plantean trabajos integrando varias fuentes, ya que cada una contará con sus propios problemas e incertidumbres (Gong, 1994).

No obstante, el recurso a contar con información de diversas fuentes ha sido frecuente en el ADI. Esta integración puede realizarse con varios objetivos (Hutchinson, 1982):

1. Para estratificar la imagen, previamente a la clasificación, de acuerdo a rasgos fisiográficos homogéneos. Esto permite reducir la varianza espectral de las distintas categorías que pretenden discriminarse (Núñez de las Cuevas *et al.*, 1983).
2. Para introducir nuevas variables en la clasificación, combinando las bandas originales, con MDE o cartografía convencional digitizada (Benediktsson *et al.*, 1990; Pons y Solé-Sugrañes, 1994; Riaño *et al.*, 2001; Salas y Chuvieco, 1995).
3. Para reclasificar algunas categorías en caso de que no hayan sido discriminadas correctamente a partir de información espectral (Hutchinson, 1982; Richards y Xia, 1999; Skidmore, 1989).

Entre los trabajos pioneros en esta integración de datos, se encuentra el método para la realización de inventarios forestales que desarrollaron varios profesores de la Universidad de California, Santa Barbara (Franklin *et al.*, 1986). Este método, aplicado a varios bosques de California, combinaba el tratamiento digital de imágenes Landsat con MDE e información de campo. A partir de las imágenes se elaboraron algunos índices de textura, incorporados a la clasificación junto a las bandas originales. Asimismo, se empleó un MDE para obtener la altitud, pendiente y orientación, lo que permitió refinar notablemente la discriminación, tanto de especies, como de densidades y alturas. Trabajos similares se han desarrollado por otros autores en el inventario forestal (Miller y Williams, 1978; Wu, 1980), y en la cartografía de modelos combustibles (Castro y Chuvieco, 1998; Riaño *et al.*, 2001; Salas y Chuvieco, 1995). Estos enfoques integrados permiten abordar clasificaciones mucho más ricas, ya que se combinan criterios espectrales (propiedades ópticas de las especies), espaciales (estructura, situación) y temporales (dinámica atmosférica, variedad fenológica, productividad), ofreciendo una evaluación más completa del territorio en estudio.

En los últimos años se han propuesto nuevas técnicas para integrar imágenes con información procedente de varias fuentes. Entre ellas, puede destacarse la teoría de la evidencia, propuesta hace algunos años por Shafer y Dempster como una extensión de la doctrina bayesiana de la inferencia estadística. Esta técnica permite trabajar tanto con variables cualitativas como cuantitativas (Gong, 1996; Richards y Xia, 1999). Por ejemplo, pueden establecerse relaciones de distinta intensidad, según estemos más o menos seguros de su fiabilidad. Esos pesos se transforman en lo que se conocen como funciones de plausibilidad *(plausibility)* y de «creencia» *(belief function)* (Srinivasan y Richards, 1990; Wilkinson y Mégier, 1990), que definen, respectivamente, la posibilidad de que una observación pertenezca a una cierta clase y la seguridad que tengamos de que lo sea. Por ejemplo, podemos afirmar que un píxel con un determinado valor de NDVI cuenta con una probabilidad de ser vegetación de 0,4 considerando los valores específicos de la vegetación (función de creencia), o también que tiene un rango de probabilidades de ser vegetación de 0,8 (función de plausibilidad), si se estima que la probabilidad de no ser vegetación es de 0,2. Estas estimaciones pueden generarse a partir de las probabilidades obtenidas en clasificadores estadísticos convencionales, o de otras fuentes más cualitativas, como el propio consejo de expertos. Richards y Ji (1999) indican varios criterios para catalogar esas inferencias en distintas clases: definitivamente verdadera, muy probable que sea verdadera, posible que lo sea, posible que no lo sea y contradictoria. Siguiendo unas reglas de combinación, propuestas por Dempster, pueden combinarse las funciones de evidencia de distintas variables, facilitando una integración mucho más matizada entre fuentes que pueden tener un carácter muy variado. La comparación entre estos enfoques y otros estadísticos más clásicos ha permitido verificar las posibilidades de esta técnica, especialmente cuando se presentan clases mixtas (Lee *et al.*, 1987).

1.7.4. *Integración de resultados*

En este último apartado consideramos los procesos de integración que se refieren a los resultados del análisis, cuando se pretenda poner en relación dos documen-

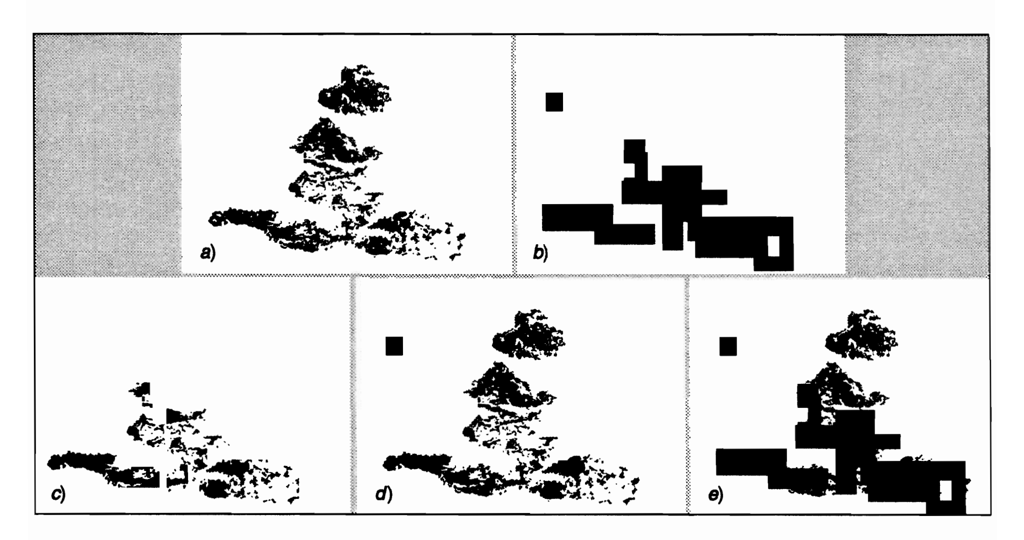


FIG. 7.31. *Esquema de integración entre resultados obtenidos a partir de dos sensores de alta (*a*) y baja (*b*) resolución: (*c*) coincidencias entre los dos; (*d*) unión entre ambas, pero prevalece la alta resolución; (*e*) unión entre ambas, pero prevalece la baja resolución.*

tos obtenidos a partir de la interpretación de imágenes de distintos sensores. Por ejemplo, podríamos comparar mapas de cobertura del suelo generados en dos períodos distintos a partir de datos MSS (años setenta) y TM (años noventa), o mapas de deforestación derivados a dos escalas distintas a partir de imágenes AVHRR y TM de la misma fecha. El primero sería un ejemplo de análisis multitemporal, que luego tendremos ocasión de comentar con más detalle (ver 7.3), y el segundo de análisis espacial multisensor, similar al muestreo estadístico en varias fases.

Aquí nos centraremos en este segundo enfoque, ya que puede resultar de interés para poner en relación modelos de interpretación que se generan a distintas escalas. Algunos ejemplos de este planteamiento podrían utilizar una imagen de alta resolución espacial para extraer los componentes puros del ALME en una imagen de baja resolución, o para simular la señal de una determinada cubierta que obtendría un sensor de peor resolución, o para comparar los inventarios de superficies deforestadas a distintos niveles de detalle. En varios trabajos sobre estimaciones de deforestación en la Amazonía (Shimabukuro *et al.*, 1994; Skole y Tucker, 1993), se ha puesto en evidencia el interés de este tipo de trabajos, ya que permiten extrapolar estimaciones realizadas a partir de un cierto nivel de detalle (por ejemplo, desde imágenes TM o HRV para sectores con buen control de campo), al conjunto de un amplio territorio que se pretende inventariar (utilizando imágenes AVHRR o Vegetation).

Una forma sencilla de fusión de datos a este nivel que venimos comentando sería la integración entre resultados binarios, por ejemplo entre áreas clasificadas como quemadas/no quemadas a dos resoluciones distintas. La integración de un producto de síntesis entre las dos podría realizarse de varias maneras (fig. 7.31 y tabla 7.5). Por un lado, podríamos optar por retener únicamente lo que se haya identificado como quemado en las dos imágenes. Este sería un enfoque conservador, que mi-

TABLA 7.5. *Esquema para la integración entre dos imágenes binarias de distinto sensor: Alta resolución (A), Baja resolución (B)*

Alta	*Baja*	*Ambos prevalecen*	*Ninguno prevalece*	*Alta prevalece*	*Baja prevalece*
1	1	1(A + B)	1(A)	1(A)	1(B)
1	0	1	0	1	0
0	1	1	0	0	1
0	0	0	0	0	0

* Se indica entre paréntesis la fuente del píxel resultate de la fusión.

nimizaría los errores de comisión (detectar como incendio lo que no lo es), aun a costa de perder posibles incendios bien clasificados en una de las dos imágenes. El planteamiento opuesto sería retener lo que haya sido identificado por cualquiera de los dos: esto reduciría el número de incendios no detectados, pero aumentaría el riesgo de falsas alarmas. En ambos casos, cuando coincidan las superficies catalogadas por ambos sensores, habrá que decidir de cuál de las dos extraemos el perímetro quemado. Parece lógico hacerlo de la imagen de alta resolución, aunque también podría haber razones para elegir la otra imagen.

Otros posibles cruces primarían una de las dos imágenes, considerando que, por cualquier razón, nos merece más crédito que la otra. Así, podríamos decidir que prevaleciera la de mayor resolución, en cuyo caso se retendrían únicamente las áreas catalogadas en esta imagen, si bien se retendrían también los píxeles de la de menor resolución cuando se puedan considerar pertenecientes a incendios detectados en la de alta resolución. Esto puede tener sentido si asumimos que la de alta puede haber detectado sólo la parte más intensamente quemada, pero no los bordes del incendio, que podrían haberse detectado mejor en la de baja resolución. Asimismo, podríamos plantear que prevaleciera la de baja resolución; esto es, se retendrían únicamente los incendios detectados en ella, si bien en aquellos que también se hayan discriminado en la de alta resolución, se retendrían los píxeles de la de alta (si siempre eligiéramos los de baja, sencillamente no haríamos fusión).

Esto es un ejemplo de las posibilidades de integración entre imágenes de distintos sensores, que puede dar idea de las perspectivas futuras que plantea un análisis integrado de la información.

2. Categorización de imágenes: clasificación digital

2.1. INTRODUCCIÓN

Todavía para la mayor parte de los usuarios de la teledetección la clasificación supone la fase culminante del ADI. Hacia ella se orientan buena parte de los realces y correcciones previamente analizados, así como algunas transformaciones.

Como fruto de la clasificación digital se obtiene una cartografía e inventario de las categorías objeto de estudio. La imagen multibanda se convierte en otra imagen, del mismo tamaño y características de las originales, con la importante diferencia de

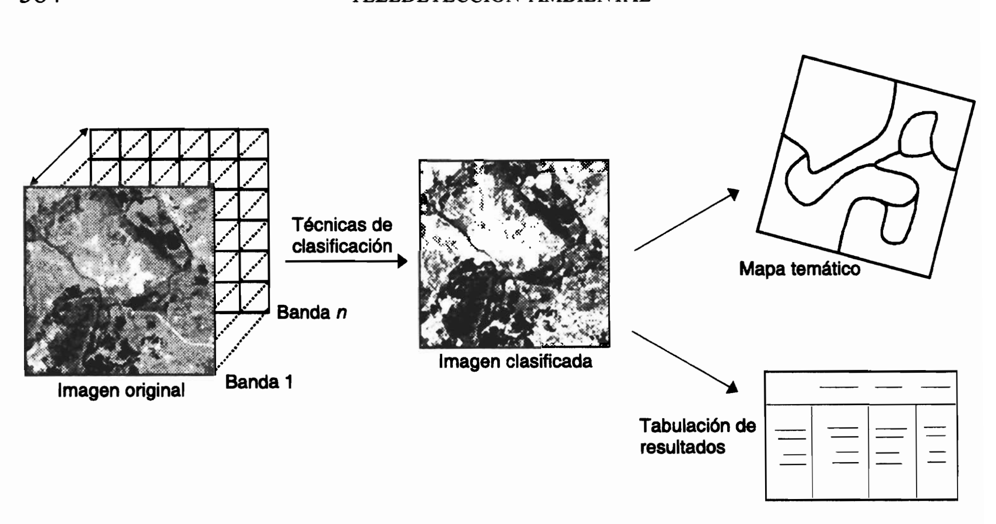


FIG. 7.32. *Fundamentos de la clasificación digital.*

que el ND que define cada píxel no tiene relación con la radiancia detectada por el sensor, sino que se trata de una etiqueta que identifica la categoría asignada a ese píxel. A partir de una imagen como ésta puede fácilmente generarse cartografía temática, así como un inventario estadístico del número de píxeles —y por tanto de la superficie— asignados a cada categoría (fig. 7.32).

De acuerdo a Cihlar et al. (1998) un método de clasificación debería de contar con las siguientes características: 1) fiable; 2) reproducible por otros, dadas las mismas variables de entrada; 3) robusto (no sensible a pequeños cambios en las condiciones de entrada, aunque permita explotar enteramente la información de esas variables); 4) exhaustivo, que cubra todo el territorio de estudio, y 5) objetivo, que no esté marcado por las decisiones del intérprete. A nuestro juicio este último punto es matizable, ya que el conocimiento del intérprete puede resolver algunos problemas en la discriminación de cubiertas, si bien estamos de acuerdo en que obtener una buenos resultados en la clasificación no debe depender únicamente de que el intérprete sea más o menos experto en el área de estudio o en el manejo de los programas.

La clasificación de la imagen se beneficia notablemente de algunos procesos de corrección y realce previamente estudiados. Sin embargo, conviene considerar que puede abordarse una clasificación exclusivamente a partir de los ND de la imagen, ya que las categorías temáticas suelen definirse de modo relativo a las condiciones específicas de la escena a clasificar. En otras palabras, en principio la clasificación digital no busca una definición absoluta de cada cubierta, que pudiera ser aplicable a cualquier imagen, sino más bien una caracterización relativa, válida para una determinada imagen y un territorio concreto (Robinove, 1981). Si adoptamos este planteamiento, no resulta preciso conocer detalladamente las condiciones de adquisición: basta identificar en la imagen las clases a discriminar, sin pretender que esa identificación sea extrapolable a otras situaciones. En resumen, en ese contexto no se trataría de establecer un modelo entre medidas digitales y parámetros físicos, sino entre medidas digitales, para un sensor, una zona y una fecha determinada, y tipos

de cubierta. En este sentido, la clasificación supone un enfoque más cualitativo, si bien, por tratarse de un proceso numérico, incorpora un aparato estadístico ciertamente importante. Lógicamente esto supone el nivel de interpretación más elemental, aunque todo lo dicho en este capítulo también es aplicable al trabajo con valores calibrados de radiancia, reflectividad o temperatura. De hecho, las tendencias más modernas en clasificación pretenden establecer leyes de validez general, aptas para una interpretación automática de la imagen, y eso necesariamente requeriría trabajar con variables físicas.

Como ya hemos indicado, la clasificación digital implica categorizar una imagen multibanda. En términos estadísticos, esto supone reducir la escala de medida, de una variable continua (los ND originalmente detectados por el sensor) a una escala categórica (tipos de cobertura) u ordinal (densidades de vegetación). La apariencia externa puede resultar muy similar entre la imagen original y la clasificada, ya que ambas presentan el mismo tamaño y pueden visualizarse en niveles de gris. Sin embargo, es importante considerar que no pueden aplicarse ciertas operaciones estadísticas a una imagen clasificada, ya que, pese a ser digital, no está medida en una escala cuantitativa, sino generalmente cualitativa. Un sencillo ejemplo bastará para explicar este razonamiento. El objetivo de los filtros espaciales (ver 6.5.4) es asimilar a reforzar los contrastes en los ND de píxeles vecinos. Esto implica que el ND de un determinado píxel se obtiene mediante algún tipo de operación aritmética con los ND de los píxeles inmediatos, lo que implica una escala de medida continua. En una clasificación de tipos de cultivo, por ejemplo, no puede realizarse ninguna operación de este tipo, ya que la categoría 1 (p. ej., cebada) y la 2 (p. ej., trigo) no tienen relación numérica entre sí (1 no es mayor o menor que 2), y, en consecuencia, no tiene ningún sentido, entre otras cosas, promediarlas. Por tanto, en imágenes clasificadas las operaciones espaciales entre píxeles vecinos deben basarse en parámetros estadísticos apropiados para variables nominales (la moda o el índice de variación cualitativa).

En resumen, al terminar el proceso de clasificación el ND de un píxel clasificado será el identificador de la clase en donde se haya incluido. Estas clases pueden describir distintos tipos de cubierta (variable nominal o categórica), o bien intervalos de una misma categoría de interés (variable ordinal). Una clasificación de especies vegetales estaría dentro del primer grupo, mientras un intento de señalar niveles de afectación en un incendio forestal o de humedad en el suelo, en el segundo.

Los primeros ensayos de clasificación digital de imágenes de satélite se basaron exclusivamente en los ND de la imagen (ya fueran originales o tras convertirlos a magnitudes físicas). Como ya sabemos, estos ND son una traducción digital de un flujo energético recibido por el sensor para una determinada banda del espectro. En consecuencia, una clasificación basada exclusivamente sobre ND puede denominarse propiamente clasificación espectral. Con ser muy rica esta información, no siempre es capaz de separar cubiertas, pues puede haber distintas categorías temáticas con un comportamiento espectral similar. En ese caso, se recomienda acudir a las otras dos dimensiones de información que contiene una imagen: la espacial y la temporal. En el primer caso, se trataría de incorporar a la clasificación la estructura o el contexto espacial en el que aparece cada píxel. En el segundo, se aportarían datos sobre su evolución estacional, lo cual es especialmente crítico para la discriminación

de cubiertas vegetales. Finalmente, puede ocurrir que ninguna de estas tres dimensiones sea suficiente para separar ciertas cubiertas, y sea preciso acudir a información auxiliar (topografía, suelos, etc.). A lo largo de este apartado veremos algunos procedimientos para abordar estos enfoques alternativos, si bien nos centraremos principalmente en la interpretación de los datos espectrales.

Simplificando las cosas, la clasificación digital de imágenes sigue cauces análogos a los que se emplean en foto-interpretación. En esta técnica, en primer lugar el intérprete identifica el patrón visual asociado a cada cubierta, de acuerdo a una serie de criterios: tono, textura, forma, contexto, disposición, etc., tal y como aparecen en unos fotogramas tipo. Posteriormente, delimita sobre el resto de las fotografías las zonas que se corresponden con ese modelo previamente definido. En otras palabras, asigna a cada categoría unas determinadas superficies, en función de la semejanza de éstas con el patrón-tipo identificado previamente. Por último, verifica sobre el terreno la interpretación realizada.

Éste es también el esquema de la clasificación digital. Basta traducir los criterios analógicos por digitales, por cuanto se realiza sobre los ND presentes en la imagen. De esta forma, pueden distinguirse las siguientes fases: 1) definición digital de las categorías (fase de entrenamiento), 2) agrupación de los píxeles de la imagen en una de esas categorías (fase de asignación), y 3) comprobación y verificación de resultados. Trataremos aquí de las dos primeras, reservando la tercera para un capítulo independiente, puesto que las técnicas de verificación son aplicables tanto a la interpretación digital como a la visual.



2.2. Fase de entrenamiento

2.2.1. *Conceptos básicos*

Para que una fotografía aérea pueda ser interpretada en detalle es preciso que exista una experiencia previa, que nos permita identificar cada una de las categorías de interés por una serie de rasgos, como son tono, textura, situación o tamaño. Es posible distinguir entre matorral y arbolado, gracias a que éste tiene una textura más rugosa; mientras la separación entre agua y suelos descubiertos se realiza sobre la diferencia de tonalidad. De la misma forma, la clasificación digital se inicia caracterizando los patrones que definen en la imagen las distintas categorías objetivo. Por cuanto se trata de una clasificación basada en los valores numéricos de los píxeles, esta caracterización también debe ser numérica; esto es, se trata de obtener el ND, o mejor aún el rango de ND, que identifica a cada categoría, para todas las bandas que intervienen en la clasificación.

Como ya hemos visto a lo largo de esta obra, diversos factores introducen una cierta dispersión en torno al comportamiento espectral medio de cada cubierta. Esto implica que las distintas categorías no se definen por un sólo ND, sino por un conjunto de ND, más o menos próximos entre sí. En términos de su clasificación digital, esto supone que existe una cierta dispersión en torno al ND medio de cada categoría, más o menos significativa según las clases que se consideren y la propia complejidad del paisaje donde éstas se asienten. Por ello, la fase de entrenamiento

resulta ciertamente compleja: se trata de definir con rigor cada una de las categorías que pretendan discriminarse, teniendo en cuenta su propia variabilidad en la zona de estudio.

Este objetivo se logra seleccionando una muestra de píxeles de la imagen, que representen adecuadamente a las categorías de interés. A partir de esos píxeles pueden calcularse los ND medios y la variabilidad numérica de cada categoría, en todas las bandas que intervienen en la clasificación. Al igual que en cualquier otro muestreo, el objetivo de esta fase es obtener los resultados más precisos con el mínimo coste. En otras palabras, identificar debidamente las distintas categorías, reduciendo a lo imprescindible los trabajos de campo. Al igual que en otras aplicaciones del muestreo, las estimaciones posteriores se basan sobre la muestra seleccionada, por lo que una incorrecta selección de ésta conducirá inexorablemente a pobres resultados en la clasificación posterior. Varios autores han comprobado que los resultados de la clasificación están mucho más influidos por la definición previa de las categorías, que por el criterio con el que éstas son posteriormente discriminadas (Gong y Howarth, 1990; Hixson *et al.*, 1980; Story y Campbell, 1986). En definitiva, la fase de entrenamiento constituye la columna vertebral de la clasificación numérica.

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado, de acuerdo a la forma en que son obtenidas las estadísticas de entrenamiento. El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado procede a una búsqueda automática de grupos de valores homogéneos dentro de la imagen. Queda al usuario, en este caso, la labor de encontrar correspondencias entre esos grupos y sus categorías de interés. Volviendo al paralelismo con la fotointerpretación, podríamos afirmar que en ésta el método supervisado es el más habitual, por cuanto se identifican sobre unos fotogramas-tipo las características de cada clase, para luego delimitar, en el resto, las zonas que se ajustan a esas características. El método no supervisado supondría, en primer lugar, identificar sobre la fotografía aérea zonas homogéneas en cuanto a tonos, textura, disposición, etc., para luego asignarlas a una de las clases temáticas establecidas en la leyenda.

Para iluminar el sentido de ambos métodos, puede ser conveniente introducir una pequeña reflexión sobre el tipo de categorías que pueden intervenir en una clasificación temática. Suelen distinguirse, a este respecto, dos tipos de clases: informacionales y espectrales (Chuvieco, 1986; Labrandero, 1978). Las primeras son las que constituyen la leyenda de trabajo que pretende deducir el intérprete (tipos de ocupación del suelo, por ejemplo). Las segundas, corresponden a los grupos de valores espectrales homogéneos dentro de la imagen, en función de ofrecer una reflectividad similar, para las bandas consideradas y en la fecha concreta de la imagen. Las categorías informacionales se establecen por el usuario, mientras las espectrales se deducen de los ND presentes en la imagen.

Idealmente habría de producirse una correspondencia biunívoca entre las dos (fig. 7.33*a*); esto es, que a cada clase informacional le corresponda un único grupo espectral y viceversa. Desgraciadamente este caso es muy poco frecuente, produciéndose, normalmente, alguna de las siguientes situaciones:

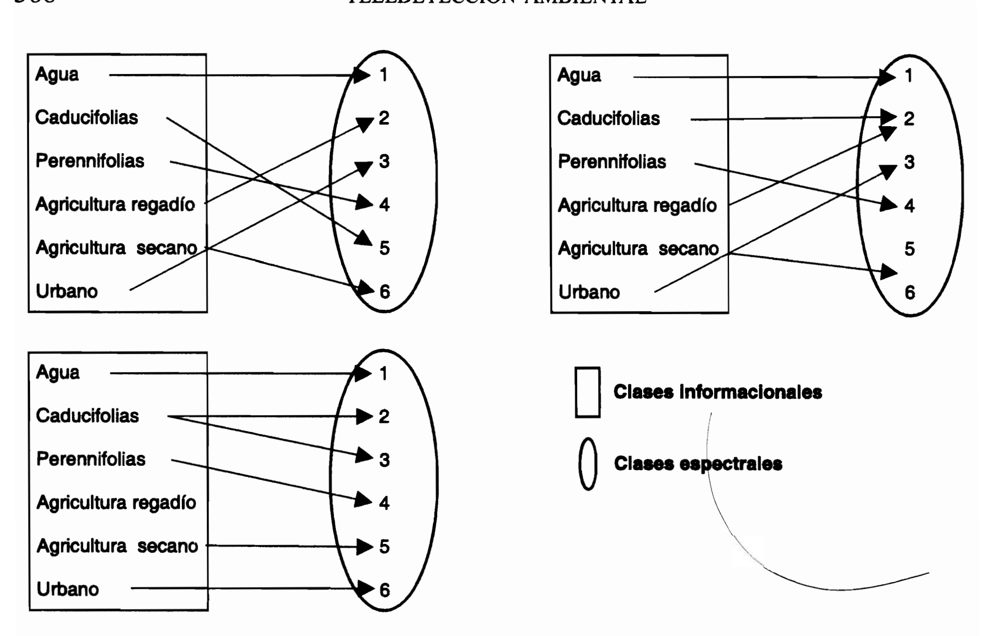


FIG. 7.33. *Relaciones entre clases informacionales y espectrales.*

1. Que una categoría de cubierta esté expresada en varias clases espectrales (fig. 7.33*b*). Por ejemplo, el pinar según su emplazamiento podría aparecer en dos grupos: uno correspondiente a solana y otro a umbría; o el agua en dos clases, de acuerdo a su profundidad o turbidez. Este problema no es muy complicado de resolver. Basta, tener en cuenta esa heterogeneidad espectral para generar dos o más grupos espectrales para cada clase informacional, fusionándolas después de la clasificación. Esto evita contar con clases muy heterogéneas espectralmente, fácilmente sujetas por tanto a confusión con otras similares.

2. Otra cosa sería que dos o más categorías informacionales compartan una sola clase espectral (fig. 7.33*c*). Esto implicaría, en pocas palabras, que algunas categorías de la leyenda no sean discriminables, a partir de la imagen con que se cuenta, sin grave peligro de confusión. En este caso, se pueden plantear varias opciones para solucionar el problema. La más sencilla sería optar por una clave más general, evitando descender a un nivel de desagregación no abordable a partir de esos datos. Por ejemplo, podría optarse por una clase denominada coníferas, en lugar de distinguir distintos tipos de pinar, o urbana, frente a distintas densidades de edificación. Ahora bien, esa solución en algunos casos no es aceptable, bien porque la confusión se dé entre categorías que no son asimilables temáticamente (por ejemplo, superposición entre núcleos rurales y rastrojeras, en imágenes de verano), bien porque las categorías objetivo sean un requisito imprescindible del trabajo (p. ej., un inventario forestal no puede aceptarse si no se discriminan un cierto número de especies). En estos casos, habría que intentar otras soluciones, como incluir en la clasificación una imagen perteneciente a otra fecha del año, en donde la separación entre categorías problemáticas sea posible (contraste primavera-

verano, para cubiertas vegetales), o acudir a criterios no espectrales, como pueden ser los derivados de la textura o situación espacial, o añadir alguna variable auxiliar (relieve, suelos, etc.).

3. Por último, puede también ocurrir que varias clases informacionales compartan clases espectrales (fig. 7.33*d*). En este caso convendría replantear la estrategia de trabajo, o acudir a las soluciones parciales comentadas en párrafos anteriores.

A la luz de este comentario, parece claro que el método supervisado pretende definir clases informacionales, mientras el no supervisado tiende a identificar las clases espectrales presentes en la imagen. De los párrafos anteriores, también puede deducirse que ninguno de los dos métodos proporciona una solución inmediata a todos los problemas que entraña una clasificación digital. Por un lado, el método supervisado puede tacharse de subjetivo y artificial, pues puede «forzarse» al algoritmo a discriminar categorías que no tengan un claro significado espectral. Por otro, el método no supervisado proporciona en ocasiones resultados de difícil interpretación, poco conectados con las necesidades del usuario final del producto. Asimismo, resulta poco claro que este método sea realmente capaz de identificar las agrupaciones naturales de la imagen. De ahí la diversidad de algoritmos y de parámetros de control revisados en la literatura, como más tarde tendremos ocasión de analizar.

En resumen, la elección entre uno y otro método dependerá de los datos y medios disponibles y de las propias preferencias personales (Townshend y Justice, 1981).

2.2.1. *Método supervisado*

El método supervisado parte de un cierto conocimiento de la zona de estudio, adquirido por experiencia previa o por trabajos de campo. Esta mayor familiaridad con el área de interés permite al intérprete delimitar sobre la imagen unas áreas suficientemente representativas de cada una de las categorías que componen la leyenda. Estas áreas se denominan, en la bibliografía anglosajona, *training fields* (áreas de entrenamiento). El término indica que tales áreas sirven para «entrenar» al programa de clasificación en el reconocimiento de las distintas categorías. En otras palabras, a partir de ellas se caracterizan cada una de las clases, para asignar más tarde el resto de los píxeles de la imagen a una de esas categorías en función de la similitud de sus ND con los extraídos como referencia.

La mayor parte de los equipos de ADI permiten localizar interactivamente las áreas de entrenamiento. Con ayuda del digitizador o ratón electrónico, el usuario introduce sobre la pantalla los vértices que definen cada una de estas áreas, asignándolas a una de las categorías definidas previamente en la leyenda. También pueden seleccionarse los píxeles que formarán parte de un área de entrenamiento a partir de un método semiautomático, conocido como «semillado» (fig. 7.34). En lugar de digitizar un polígono completo, basta que el intérprete localice un píxel central, a partir del que se agregan los píxeles vecinos, en función de su proximidad espectral y espacial al introducido como semilla, hasta formar un polígono completo. La ventaja sobre el criterio anterior se basa en la garantía de que los píxeles seleccionados de esta forma tendrán características espectrales similares al píxel semilla, evitándo-

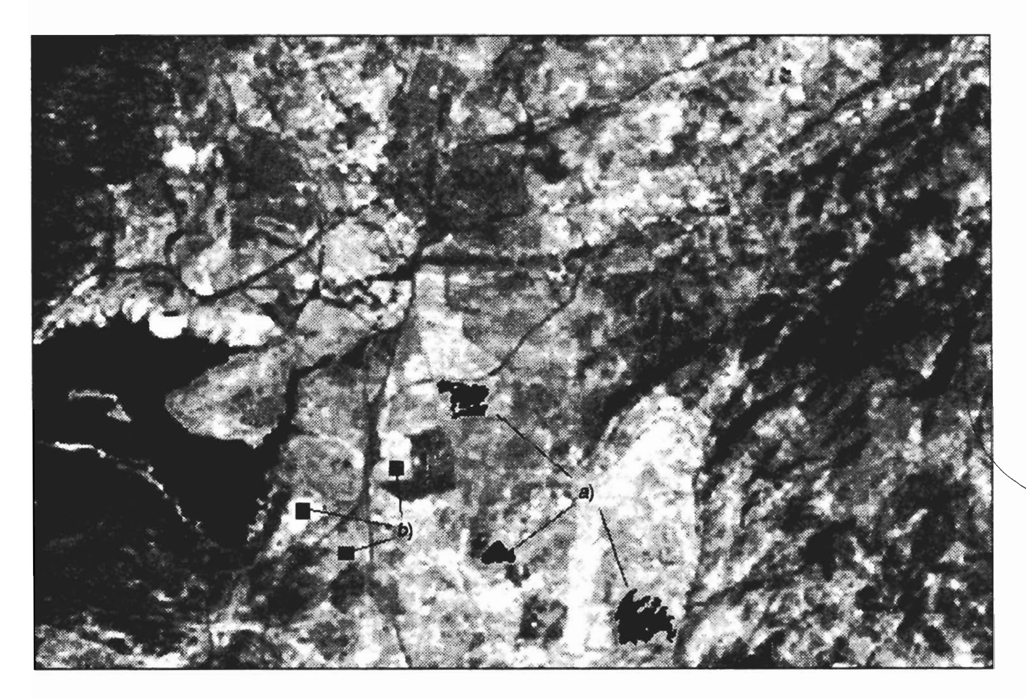


FIG. 7.34. *Selección de píxeles de entrenamiento por semillado (*a*) y utilizando polígonos regulares (*b*).*

se así añadir ruido involuntario a la definición de las clases espectrales. Los parámetros para asignar los píxeles vecinos al de origen dependen de cómo crezca la varianza global de la muestra, señalando el intérprete algún valor límite, según el conocimiento que tenga de la heterogeneidad de la categoría que está delimitando.

Para una localización más precisa de estas áreas de entrenamiento pueden ser de gran ayuda los trabajos de campo y otros documentos auxiliares —como la fotografía aérea o la cartografía convencional—, teniendo en la mente que debe tratarse de ejemplos suficientemente representativos y homogéneos de la clase que pretende definirse. Acabada la delimitación de una parcela de entrenamiento, pueden seleccionarse otras para la misma categoría, o bien culminar con ella la definición de esa clase. En general, resulta conveniente seleccionar varias áreas por categoría, a fin de reflejar adecuadamente su variabilidad en la zona de estudio.

Independientemente del método elegido para seleccionar las áreas de entrenamiento, conviene que exista un control de campo suficiente, en fecha próxima a la adquisición de la imagen, y mejor aún si es simultánea, para garantizar la consistencia entre lo medido en el terreno y por el sensor. En estos trabajos será muy interesante realizar algunas medidas radiométricas, aprovechando la creciente disponibilidad de radiómetros portátiles (fig. 7.35), lo que permite interpretar con más rigor la señal recibida por el sensor o seleccionar las bandas más adecuadas para el tratamiento (Barret y Curtis, 1999; Milton *et al.*, 1995).

Finalizada la selección de las áreas de entrenamiento, se calculan las estadísticas elementales de cada categoría, a partir de los ND de todos los píxeles incluidos en las

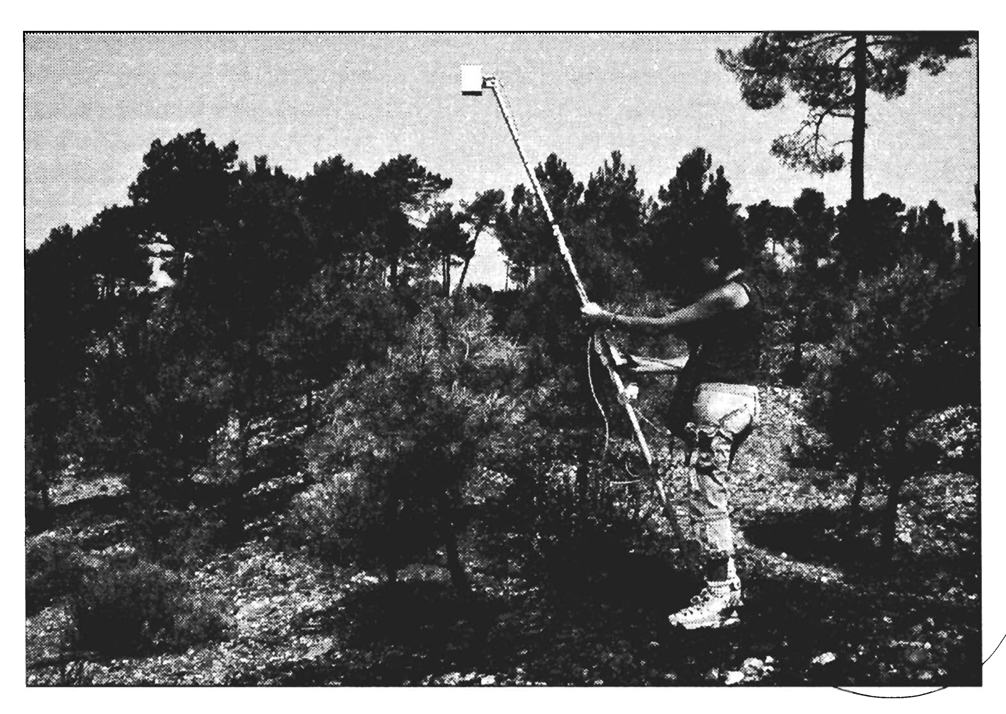


FIG. 7.35. *El empleo de un radiómetro de campo permite verificar el comportamiento espectral de una cubierta.*

áreas de entrenamiento de esa clase, teniendo en cuenta todas las bandas que intervendrán en la clasificación. Se asume que las áreas de entrenamiento son fieles representantes de las distintas categorías, y que, por tanto, las medidas extraídas a partir de sus ND definen convenientemente a esas clases. De aquí que sea crucial su correcta selección, ya que de otro modo se estaría forzando al algoritmo a clasificar áreas heterogéneas. En consecuencia, la clasificación estaría viciada de partida, al pretender discriminar categorías con escaso significado espectral. Conviene especialmente evitar áreas de entrenamiento que puedan ser heterogéneas, o clases espectrales presentes en la imagen que no se hayan identificado con ninguna clase de entrenamiento.

Un último aspecto a considerar en la selección de las áreas de entrenamiento se refiere a los requisitos estadísticos que garantizan el grado de representatividad de las distintas categorías. Como antes se comentó, este proceso implica una forma peculiar de muestreo espacial. Por ello, conviene tener en cuenta algunos criterios habituales en este tipo de técnicas para elegir el tamaño y la distribución más idónea de la muestra, así como para realizar estimaciones a partir de ella.

En cuanto al tamaño, se requiere seleccionar un mínimo de $m + 1$ píxeles por categoría, siendo m el número de bandas que integran el análisis (Schowengerdt, 1997). Conviene, no obstante, superar con creces este límite mínimo. Diversos autores recomiendan seleccionar un número de píxeles comprendido entre 10 m y 100 m por categoría (Jensen, 1996; Mather, 1998). Este número parece fácilmente accesible con los sensores que habitualmente han servido de entrada en la clasificación,

pero puede ser más complicado si se parte de equipos hiperespectrales, en donde el número de bandas de entrada sea muy numeroso. Esto sugiere, de nuevo, el interés por seleccionar adecuadamente las bandas más convenientes para la clasificación.

Por otro lado, ese número mínimo de píxeles se relaciona estrechamente con el grado de asociación espacial entre los ND de la imagen. El muestreo convencional considera que las muestras seleccionadas son aleatorias e independientes. Como antes indicamos, esta asunción no es válida en nuestro caso, por cuanto una parcela de entrenamiento alberga a píxeles vecinos, afectados por el fenómeno de la autocorrelación espacial. En pocas palabras, esta asociación, comprobada en diversos trabajos sobre imágenes de satélite (Congalton, 1988), supone que la información original extraída de un número de píxeles contiguos es menor que si fue obtenida a partir de otros dispersos. En suma, resulta más conveniente elegir varios campos de pequeño tamaño que uno sólo de mayores dimensiones, ya que tenderá a infravalorarse la variabilidad de esa categoría. También se puede optar por seleccionar píxeles aleatoriamente, dentro de campos de mayor tamaño, en lugar de admitirlos todos (Campbell, 1996; Mather, 1998). Otros autores recomiendan seleccionar píxeles aislados de cada categoría, en número suficiente para estimar adecuadamente la variabilidad espectral de dicha clase (Gong y Howarth, 1990). Este criterio puede ser recomendable cuando existe suficiente control del terreno. En zonas de difícil acceso resulta poco operativo.

Respecto a la distribución, conviene tener en cuenta las propias características de la imagen, intentando abarcar las variaciones espaciales que se presentan en cada categoría: su orientación, pendiente, densidad, vigor, contenido de humedad, tipo de suelo, etc. En este sentido, varios autores han subrayado que la variabilidad de una cubierta es directamente proporcional a la resolución del sensor (Cushnie, 1987). Dicho de otro modo, cuanto mayor sea el detalle espacial registrado en la imagen, mayor será también su sensibilidad para detectar las variaciones internas de una categoría, ocultas de otra forma bajo un píxel de mayor tamaño. Por cuanto a mayor heterogeneidad, mayor mezcla con clases similares —y, en última instancia, mayor riesgo de confusiones en la asignación posterior—, un incremento en la resolución espacial puede complicar la clasificación digital. Este hecho, que parece contradecir el sentido común (mayor resolución espacial, mayor precisión), fue puesto de manifiesto ya hace algunos años por diversos autores, que lo denominaron «*scene noise*», ruido de la escena (Markham y Townshend, 1981). El efecto se ha comprobado con más nitidez en los tipos de cubierta más heterogéneos, como es el caso de las áreas urbanas, en donde un píxel de mayor tamaño facilita adquirir una señal promedio de distintos componentes, mientras cuanto más se reduzca el píxel, los efectos de frontera son más intensos (Toll, 1984). Por el contrario, en categorías agrícolas y forestales, ese efecto es menos nítido, siendo más convenientes las imágenes de alta resolución (Hopkins *et al.*, 1988; Irons y Kennard, 1986).

La delimitación de las áreas de entrenamiento sobre la imagen Torre100 se realizó en nuestro caso a partir del trabajo de campo. Para facilitar el carácter didáctico de la exposición, solamente seleccionamos siete categorías: áreas urbanas, pastizales, pinar-encinar (los caducifolios no tienen todavía hojas en esta fecha), matorral, láminas de agua, suelos descubiertos y cultivos de secano (los de regadío no están presentes en esta época del año).

2.2.3. *Método no supervisado*

Este método se dirige a definir las clases espectrales presentes en la imagen. No implica ningún conocimiento del área de estudio, por lo que la intervención humana se centra más en la interpretación que en la consecución de los resultados.

En esta estrategia, se asume que los ND de la imagen forman una serie de agrupaciones o conglomerados *(clusters)*, más o menos nítidos según los casos. Estos grupos equivaldrían a píxeles con un comportamiento espectral homogéneo y, por tanto, deberían definir clases temáticas de interés. Desgraciadamente, como se vio más arriba, estas categorías espectrales no siempre pueden equipararse a las clases informacionales que el usuario pretende deducir, por lo que resta a éste interpretar el significado temático de esas categorías espectrales.

El método para definir los agrupamientos espectrales es muy similar al empleado en otras técnicas de clasificación automática de datos (Hand, 1981; Johnston, 1978). Se basa en la selección de tres parámetros: 1) variables que intervienen en el análisis; 2) criterio para medir la similitud o distancia entre casos, y 3) criterio para agrupar los casos similares.

En nuestro contexto, las variables son las bandas espectrales seleccionadas para la clasificación, ya sean éstas originales o fruto de alguna transformación. Los casos son los píxeles que componen la imagen, cada uno de ellos definido por tantos ND como bandas intervienen en el análisis. En este espacio multivariado se trata de encontrar los grupos de píxeles con ND similares, para luego equipararlos con alguna de las clases informacionales de nuestra leyenda.

El método para encontrar esos grupos homogéneos puede ilustrarse con el caso más simple, en el que estuviéramos trabajando con dos bandas (IRC y R, por ejemplo). En un gráfico bivariado aparecerían tantos puntos como píxeles, localizados de acuerdo a sus ND en cada banda (fig. 7.36). El gráfico evidencia la existencia de agrupaciones de píxeles, con ND similares en las dos bandas, que podrían identificar clases temáticas de interés. Por ejemplo, los puntos situados en el vértice inferior izquierdo corresponderían a píxeles con ND bajos en las dos bandas (*c*), los situados en el superior derecho serían píxeles con altos valores en ambas bandas (*b*), mientras los correspondientes al extremo superior izquierdo implican ND bajos en la banda R y altos en el IRC (*a*). En estas regiones del espectro, podríamos identificar estos grupos como pertenecientes a agua, suelos desnudos o vegetación, respectivamente, aunque en esta fase sólo nos interesa conocer que se trata de grupos homogéneos y distintos entre sí.

La delimitación de cada grupo espectral se inicia señalando dos criterios: uno que mida la similitud entre píxeles, y otro que marque las condiciones del proceso de agrupamiento. En cuanto al primer aspecto, se han propuesto diversos criterios para medir la distancia entre píxeles. El más utilizado se basa en la distancia euclidiana:

$$d_{a,b} = \sqrt{\sum_{i=1,m} (\mathrm{ND}_{a,i} - \mathrm{ND}_{b,i})^2} \qquad \{7.29\}$$

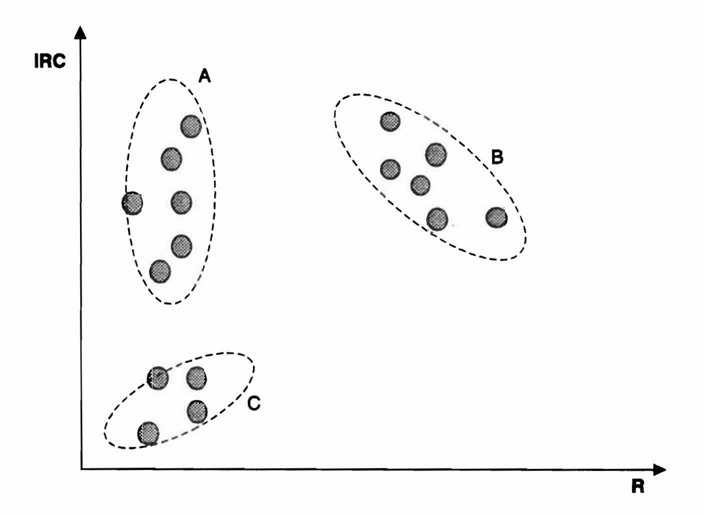


FIG. 7.36. *La clasificación no supervisada intenta identificar los grupos espectrales presentes en la imagen.*

donde $d_{a,b}$, indica la distancia entre dos píxeles cualquiera a y b; $ND_{a,i}$ y $ND_{b,i}$, los niveles digitales de esos píxeles en la banda i, y m el número de bandas. También pueden utilizarse otros criterios para medir la distancia entre píxeles, como sería el caso de la distancia media o la de Mahalanobis (Rebollo y Orti, 1980), si bien la distancia euclidiana resulta la más habitual en este tipo de aplicaciones.

En cuanto al algoritmo de agrupamiento, las opciones también son muy numerosas. Uno de los más extendidos es el denominado ISODATA (Duda y Hart, 1973), gracias a contar con un mecanismo iterativo bastante sólido. En esencia, este algoritmo procede a partir de las siguientes fases (fig. 7.37):

1. Se señalan una serie de centros de clase, de acuerdo al número y forma indicados por el usuario.
2. Se asignan todos los píxeles de la imagen al centro de clase más próximo, utilizando el criterio de distancia antes comentado.
3. Se calculan de nuevo los centros de clase, teniendo en cuenta los valores de todos los píxeles que se le hayan incorporado en la fase anterior.
4. Se reordenan los centros de clase en función de los parámetros de control indicados por el usuario (distancia mínima entre grupos, tamaño mínimo de un grupo, varianza máxima de un grupo y número de grupos).
5. Se vuelven a asignar todos los píxeles de la imagen al centro más cercano, el cual —debido al desplazamiento registrado en (3)— no tiene por qué coincidir con la asignación realizada en (2).
6. Si el número de píxeles que han cambiado de categoría es inferior al señalado por el usuario se termina el proceso; en caso contrario, se retorna a la fase (3).

En cada iteración el algoritmo se pregunta: ¿se ha alcanzado el número máximo de grupos para interrumpir el agrupamiento?, ¿algún grupo tiene un número de píxeles inferior al mínimo señalado, en cuyo caso se suprime?, ¿algún grupo está a

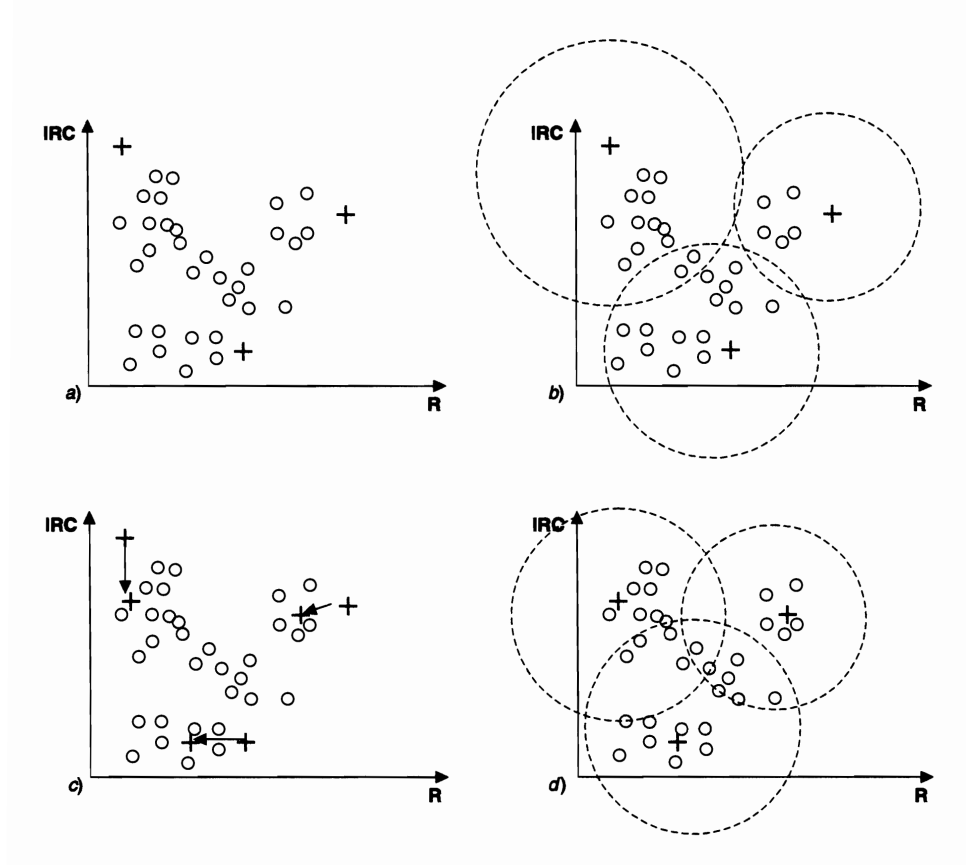


FIG. 7.37. *Esquema del algoritmo ISODATA. (*a*) selección de los centros de clase iniciales; (*b*) asignación al centro más próximo; (*c*) desplazamiento de los centros de clase; (*d*) segunda iteración con asignación al más próximo.*

una distancia inferior a la mínima señalada entre grupos para realizar una fusión?, ¿algún grupo cuenta con una varianza superior a la máxima señalada para que sea dividido?

Desde el punto de vista estadístico, este algoritmo parece bastante adecuado para delimitar los grupos de valores homogéneos dentro de la imagen (Rebollo y Orti, 1980), si bien pueden darse en ocasiones bucles indefinidos, cuando los parámetros de control no están bien definidos y el algoritmo entra en una cadena de separaciones y fusiones interminable.

Otro problema, más habitual para el usuario, atañe a la elección de los parámetros de control más convenientes para la imagen que se interpreta, puesto que lo habitual será que no conozcamos de entrada el número de grupos espectrales presentes en la imagen, ni el valor idóneo de dispersión interna o de distancia entre grupos. De esta forma, el análisis no supervisado se convierte en un proceso exploratorio, en donde el intérprete establece unos valores arbitrarios que se van modificando a la vista de los resultados.

Finalmente, el método no supervisado también presenta como inconveniente el

notable volumen de cálculo que precisa. Habitualmente, un buen agrupamiento se consigue tras un número alto de iteraciones, por lo que este criterio resulta muy lento para clasificar imágenes muy extensas. Por esta razón, suele extraerse una muestra sistemática de píxeles (1 de cada 4, 8 o 16, por ejemplo) para calcular sobre ellos los centros de clase, que luego se clasifican con alguno de los criterios de asignación que veremos en el siguiente epígrafe. En este caso, no se clasifica la imagen completa, pero sí pueden identificarse los grupos presentes en ella, objetivo último del método no supervisado.

Con este enfoque, si bien algunos autores consideran el método no supervisado como una forma específica de clasificación —esto es, como una estrategia completa, que abarca tanto la fase de entrenamiento como la asignación de los píxeles de la imagen a las categorías de la leyenda—, a nuestro juicio supone más bien una forma alternativa de obtener las estadísticas de entrenamiento. En otras palabras, el análisis no supervisado se orienta no tanto a la clasificación de la imagen, como a definir precisamente los grupos o categorías que intervendrán en la clasificación propiamente dicha. En este sentido, el método no supervisado podría considerarse como exploratorio (Mather, 1998), dirigido a deducir las clases espectrales presentes en la imagen. Eso es especialmente importante cuando se adoptan criterios de clasificación que asumen una distribución normal de los datos. El análisis no supervisado podría indicarnos si efectivamente esas clases informacionales tienen un sentido espectral claro o, por el contrario, algunas de ellas presentan una distribución bimodal o multimodal (o, lo que es lo mismo, se presentan en varias categorías espectrales).

Como en el caso del método supervisado, es necesario analizar los píxeles incluidos en cada grupo para obtener sus medidas estadísticas elementales: media, desviación típica, mínimo, máximo, etc., que servirán para abordar la fase posterior de clasificación.

En el caso de la imagen Torre100, el análisis no supervisado se realizó sobre las 6 bandas no térmicas del sensor, extrayendo una muestra de 1 de cada 8 líneas y columnas. Se señalaron como parámetros de control los siguientes: 30 iteraciones, entre 12 y 20 grupos, 5 como umbral de tamaño mínimo de cada grupo, 2 desviaciones típicas como dispersión máxima en un grupo para dividirlo, y 1 como distancia mínima entre grupos para que fueran unidos. Con este esquema se generaron 17 clases temáticas, que fueron comparadas con las estadísticas generadas del proceso supervisado para proceder a la fase de asignación.

2.2.4. *Métodos mixtos*

Como ya apuntamos, tanto el método supervisado como el no supervisado cuentan con ventajas e inconvenientes (Cihlar *et al.*, 1998; Hoffer y Swain, 1980; Justice y Townshend, 1981). El primero resulta muchas veces subjetivo, pues el usuario establece *a priori* unas categorías sin valorar las características espectrales de la imagen. El segundo, no garantiza que las clases deducidas tengan significado para el usuario del producto, además de ser de difícil verificación.

Con objeto de paliar los inconvenientes de ambos métodos, se han propuesto diversas alternativas que los combinan de alguna forma. Estos métodos mixtos pueden agruparse en dos bloques:

1. Por un lado, se sitúan aquellos trabajos que emplean el análisis supervisado para «guiar» al no supervisado. En este caso, el conocimiento del intérprete se utiliza para orientar la búsqueda de esos grupos espectrales homogéneos. Por ejemplo, puede aplicarse el método no supervisado a áreas de la imagen con una cobertura conocida, lo que facilitaría la definición espectral de dicha cubierta (Hoffer y Fleming, 1978; Justice y Townshend, 1981). Otra forma de orientar el análisis no supervisado, consiste en introducir los ND medios de las categorías de interés —obtenidas a partir de las áreas de entrenamiento— como centros iniciales de grupo. Gracias a ello, el proceso iterativo de búsqueda se reduce notablemente, a la vez que se predispone la formación de grupos con un significado temático.

2. Por otro lado, el análisis supervisado y el no supervisado pueden combinarse gracias a aplicarlos separadamente sobre la misma imagen, para luego sintetizar las medidas extraídas por ambos. Se asume que las categorías deducidas por los dos métodos pueden complementarse mutuamente, ganando en significado espectral e informacional las clases resultantes. Algunos autores, por ejemplo, emplean el análisis no supervisado para estratificar la imagen, quedando el supervisado para las áreas no clasificadas previamente (Bruneau y Gautier, 1981; Núñez de las Cuevas *et al.*, 1983). También pueden combinarse categorías deducidas por los dos métodos, empleando un algoritmo de agrupación jerárquico. Esto permite crear un nuevo conjunto de categorías en donde se combina la información obtenida por ambos métodos (Chuvieco y Congalton, 1988). En breves palabras, se trata de clasificar conjuntamente las categorías deducidas por el análisis supervisado y no supervisado sobre la misma imagen. Esta clasificación conjunta permite obtener tres tipos de grupos: unos formados por categorías supervisadas y no supervisadas; otros, sólo por categorías supervisadas, y un tercero, sólo por categorías no supervisadas. El primer grupo identifica aquellas clases seleccionadas por el intérprete que cuentan con un significado espectral claro. El segundo corresponde a clases informacionales con escaso significado espectral. Éstas, al menos *a priori*, resultarán de difícil asignación, ya que no se identifican con agrupaciones naturales de la imagen. Por último, el tercer grupo se refiere a clases espectrales no asimilables a la leyenda propuesta por el usuario. A partir del análisis de estos dos últimos grupos, el intérprete puede refinar el esquema de clasificación propuesto inicialmente.

Otro método híbrido propuesto en los últimos años parte de generar una compresión espectro-espacial de las bandas de entrada utilizando la distribución de frecuencias en cada banda y técnicas de contexto, de cara a generar centros de grupo automáticamente. Estos centros sirven de semilla para el primer agrupamiento, que se realiza desde cada píxel de la imagen al centro más cercano. Los grupos resultantes se combinan utilizando criterios de mínima distancia espacial (adyacencia) y espectral (ángulo del vector que une los centros y diferencia cuadrática entre sus ND). Una vez obtenidos los grupos deseados, que en su última fase se combinan de acuerdo a la supervisión que realiza el intérprete, éste etiqueta el resultado final (Cihlar *et al.*, 1998).

2.2.5. *Análisis de las estadísticas de entrenamiento*

Independientemente del método empleado en definir la fase de entrenamiento, antes de abordar el proceso de clasificación propiamente dicho, conviene reflexio-

nar sobre la separabilidad de las categorías seleccionadas. Se trata de evaluar si esas clases puedan discriminarse sin grave riesgo de error. Si se comprueba que dos o más son muy similares lo más probable es que haya confusión entre ellas, por lo que resultaría aconsejable o bien revisar las estadísticas de entrenamiento, para confirmar si han sido bien seleccionadas las áreas de entrenamiento, o adoptar una leyenda más general, con nuevas categorías que supongan una mezcla de las que ofrecen mayor riesgo de confusión, o utilizar otro tipo de información de entrada (imágenes de otras fechas, información auxiliar).

Existen varios métodos —tanto gráficos como numéricos— para evaluar las estadísticas de entrenamiento. Entre los gráficos, el más elemental es un diagrama de signaturas, donde figuran, en abcisas, las bandas que intervienen en el análisis, mientras en ordenadas los ND o reflectividad medios de cada categoría. Si los valores de entrada para la clasificación son reflectividades, entonces ese gráfico sería equivalente a las firmas espectrales presentadas en el capítulo 2, si bien hay que tener en cuenta aquí que las bandas espectrales son mas anchas que las que proporciona un espectro-radiómetro. Con estas salvedades, este gráfico resulta muy útil para proporcionar una primera valoración de las tendencias espectrales de cada categoría. Identifica, además, aquellas bandas en las que manifiesta un comportamiento peculiar respecto a clases vecinas. Las líneas paralelas y próximas indican un probable solape entre categorías, mientras las intersecciones entre líneas manifiestan las bandas donde es más probable separar a las categorías que representan.

En el caso de la imagen de Torrelaguna, la tabla 7.6 recoge las medidas estadísticas elementales de las áreas de entrenamiento previamente seleccionadas. En este caso trabajaremos con las imágenes ya corregidas a reflectividad (utilizando el método de Chávez comentado en el capítulo 6). En esta tabla, el valor medio nos informa de la tendencia espectral de esa cubierta, mientras la desviación típica refiere al grado de homogeneidad que aparece en torno a ese valor central. Hemos incluido también el coeficiente de variación (definido como la proporción de la desviación típica en relación a la media de cada categoría), puesto que nos permite entender mejor la variabilidad relativa de las distintas cubiertas (tabla 7.7).

Siendo consciente de la gran heterogeneidad de las categorías urbanas, procuramos seleccionar únicamente áreas muy homogéneas, con objeto de evitar una sobre-dimensión de esta categoría. Gracias a eso, los valores de desviación típica de

TABLA 7.6. *Media (x) y desviación típica (DT) de las categorías seleccionadas (la reflectividad está multiplicada por cien)*

Banda	*Urbano*		*Pastizal*		*Matorral*		*Pinar-encinar*		*Suelo*		*Cultivo*		*Agua*	
ETM	*X*	*DT*	*X*	*DT*	*X*	*DT*	*X*	*DT*	*X*	*DT*	*X*	*DT*	*X*	*DT*
1	10,45	2,20	5,57	0,77	5,31	1,95	1,35	0,61	13,16	5,03	4,49	0,83	2,82	0,41
2	1,12	1,93	7,51	0,68	6,29	2,32	2,49	0,79	15,74	5,66	5,39	1,08	3,21	0,29
3	15,65	2,66	9,44	1,12	9,52	3,94	3,32	0,83	22,76	7,64	5,84	1,28	3,29	0,38
4	19,33	2,54	28,80	3,85	16,80	4,02	17,53	3,86	25,71	4,77	30,84	3,28	1,60	0,19
5	21,88	2,59	26,50	1,26	22,62	6,67	9,39	1,75	34,34	8,71	14,87	2,11	2,95	0,18
7	17,04	2,70	15,54	1,54	15,18	4,73	5,42	0,94	26,76	8,15	7,75	1,15	2,65	0,27

TABLA 7.7. *Coeficiente de variación de las categorías seleccionadas*

Banda ETM	*Urbano*	*Pastizal*	*Matorral*	*Pinar-encinar*	*Suelo*	*Cultivo*	*Agua*
1	21,02	13,83	36,70	45,05	38,24	18,44	14,67
2	17,37	9,07	36,86	31,83	35,97	19,98	8,99
3	16,98	11,86	41,37	25,06	33,58	21,88	11,51
4	13,14	13,37	23,92	22,01	18,55	10,63	11,54
5	11,81	4,77	29,50	18,64	25,37	14,17	6,11
7	15,85	9,88	31,13	17,26	30,47	14,84	10,14

las áreas urbanas son bastante bajos. Entre las categorías de vegetación, destacan los altos valores de la mezcla pinar-encinar, lo que nos indica que se trata de una categoría mixta que puede presentar problemas para su posterior discriminación. Los suelos también ofrecen valores bastante heterogéneos, en este caso por la diversidad de condiciones litológicas en el área de estudio. El agua, como parece lógico, ofrece los valores más homogéneos, pese a haber seleccionado muestras en varios embalses.

A partir de estos parámetros, puede construirse el gráfico de signaturas (fig. 7.38), tal y como se describió más arriba. Se aprecia ya una primera valoración de los rasgos espectrales de cada tipo de cobertura. El agua ofrece el comportamiento más peculiar, con valores inferiores según se avanza hacia el SWIR. Los cultivos también ofrecen una clara diversidad, al ser grande su contraste entre las bandas 4 y 3-5. Similar patrón ofrecen los pinares-encinares, aunque los valores de reflectividad son más bajos. Los suelos descubiertos presentan la reflectividad más alta en todas las bandas, salvo la IRC, siendo más prominente en la 5, mientras las superficies urbanas presentan un comportamiento similar, aunque con menor reflectividad en todas las bandas. Los pastizales ofrecen un comportamiento similar a los cultivos en esta época del año, si bien con valores más altos en las bandas cortas.

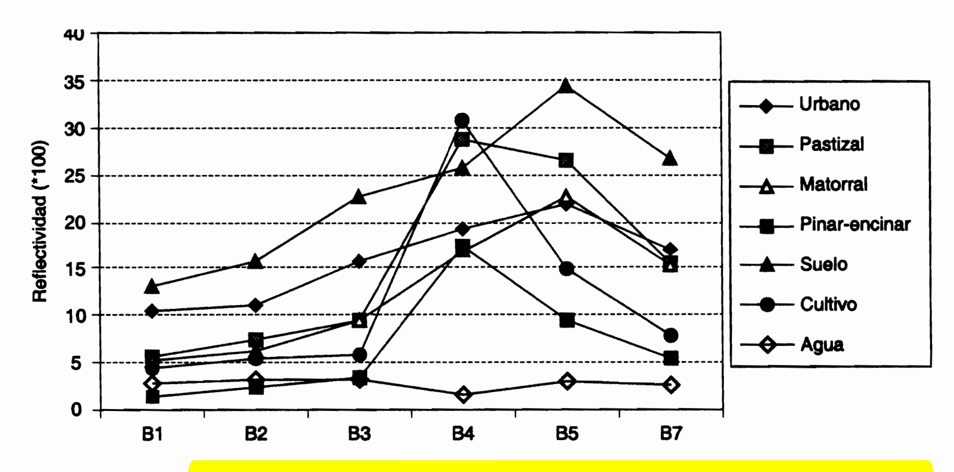


FIG. 7.38. *Gráfico de signaturas espectrales para las categorías seleccionadas.*

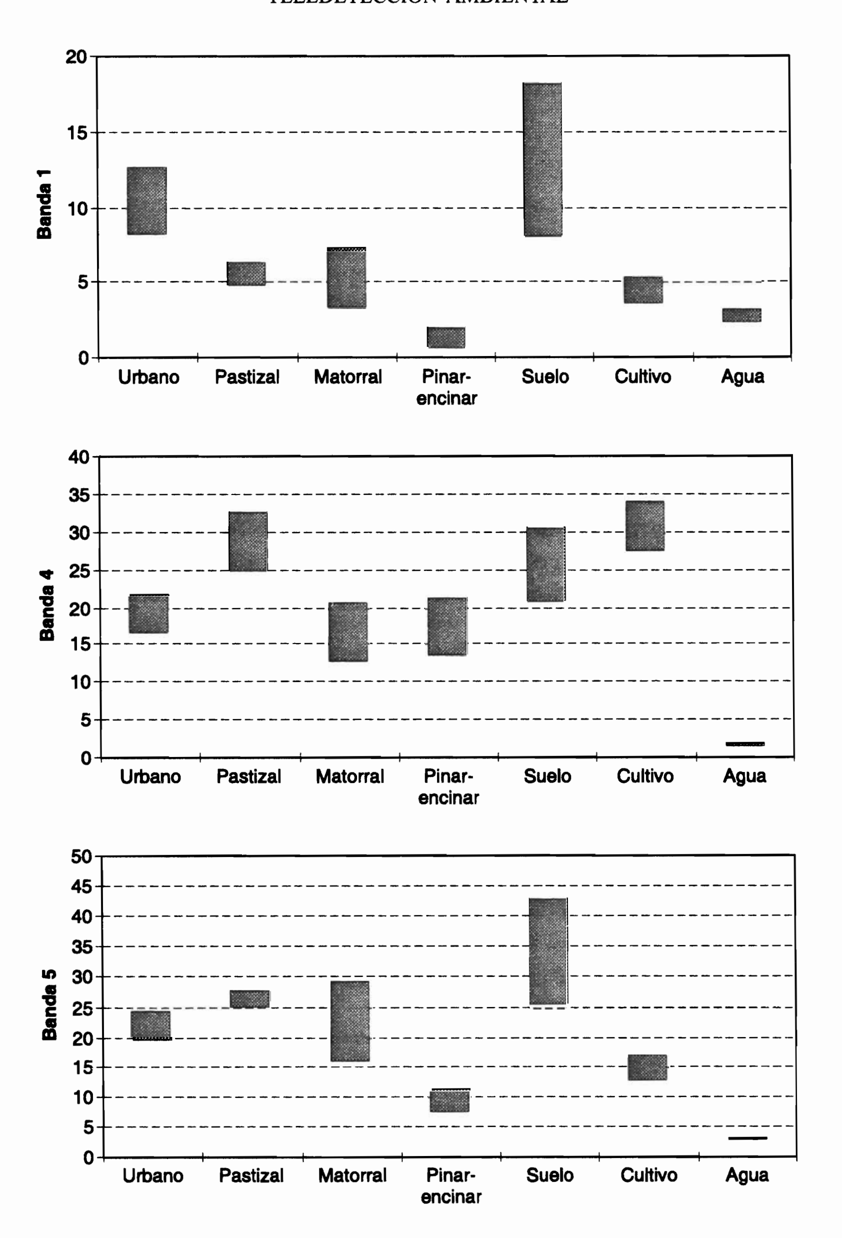


FIG. 7.39. *Diagrama de solape espectral entre cubiertas.*

En este gráfico se ofrecen únicamente los valores medios, sin considerar la variación propia de cada categoría, principal responsable de las confusiones con otras clases vecinas. En consecuencia, para tener una idea más rigurosa de posibles problemas de separabilidad, puede construirse un gráfico del «solape» espectral entre clases. Se trata de un diagrama de barras que recoge, en cada banda y para cada categoría, el rango digital cubierto por la media ± una o dos desviaciones típicas. En el caso de la figura 7.39, hemos recogido los solapes entre tres bandas bastante contrastadas

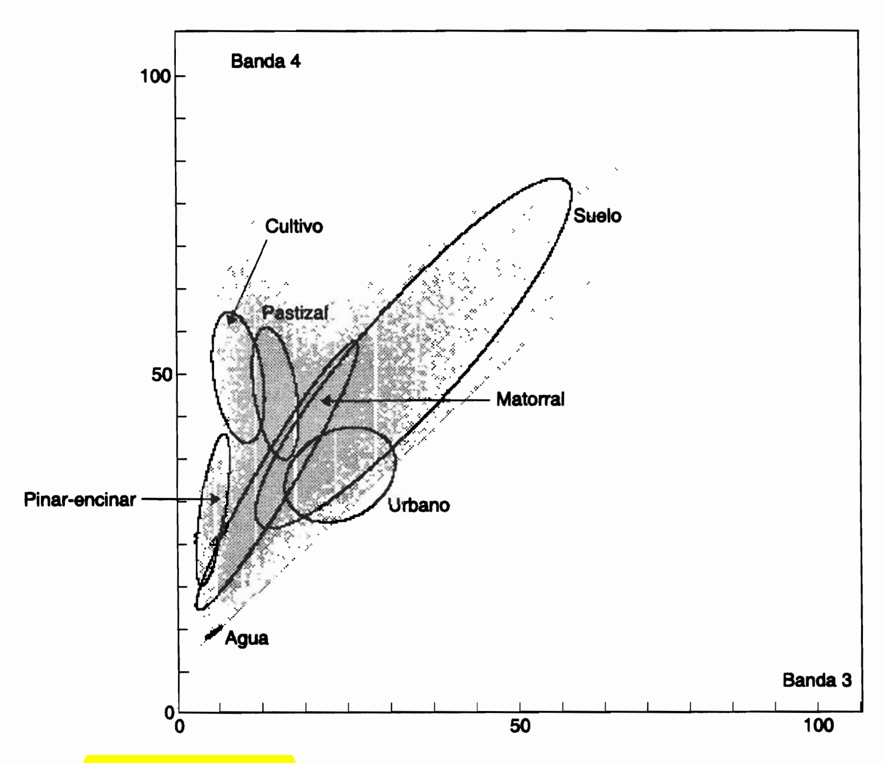


FIG. 7.40. *Elipses de dispersión espectral de las categorías seleccionadas para las bandas 3 y 4.*

(1, 4 y 5). Observamos cómo ciertas cubiertas muestran rangos similares en algunas bandas (p. ej., el agua y las cubiertas vegetales en la banda 1), pero se separan nítidamente en otras (en la 4, especialmente), mientras otras manifiestan una mayor similitud en todas ellas (urbano-matorral). El suelo descubierto tiende a presentar los valores mas altos, lo que permite separarlo bien en la mayor parte de las bandas, aunque hay pequeñas confusiones en todas ellas, debido a su alta variabilidad.

Otra forma de representar los solapes entre categorías, consiste en realizar un histograma de frecuencias de los ND que la componen. Por cuanto aquí sólo se cuenta con una muestra (los píxeles de las áreas de entrenamiento), una alternativa para representar esta distribución de frecuencias parte de asumir que los ND en el seno de cada categoría se distribuyen normalmente. Esto permite estimar su distribución, a partir de conocer su media y desviación típica. De esta forma, se construye la figura 7.40, que ofrece otra visión de los problemas de superposición entre clases, dibujando la elipse de la distribución normal para todas las clases que estamos considerando. La extensión de la elipse se ha fijado a 2 desviaciones típicas de la media. Este gráfico permite observar con mayor nitidez los posibles solapes entre categorías, y el gran efecto que tiene trabajar con categorías muy dispersas, ya que tenderán a «invadir» el rango espectral de otras. Eso es lo que ocurre con el suelo (la elipse mayor) que prácticamente ocupa todo el espacio de variación de la clase urbano, y, en menor medida, el correspondiente al matorral. En el extremo opuesto estaría el agua, que no muestra confusión con ninguna categoría.

Junto a los procedimientos gráficos, existen algunos criterios cuantitativos que permiten evaluar numéricamente la posibilidad de discriminar las distintas categorías. El más sencillo consiste en calcular la distancia normalizada entre dos categorías (dn_{AB}) (Swain y Davis, 1978):

$$dn_{A,B} = \frac{\left|\overline{\text{ND}}_A + \overline{\text{ND}}_B\right|}{s_A + s_B} \qquad \{7.30\}$$

calculada como la diferencia absoluta entre las medias de dos categorías (A y B), en proporción a la suma de sus desviaciones típicas. Este cálculo se aplica a cada par de bandas que intervienen en la clasificación, promediándose su valor para obtener una matriz de separabilidad.

Un poco más compleja, y también más versátil, es la divergencia estadística (Swain y Davis, 1978; Thomas *et al.*, 1987). Parte de asumir que los ND en una categoría se distribuyen normalmente, considerando la separabilidad como medida del solape entre categorías vecinas. Por cuanto se trata de calcular ese valor para un espacio multivariado (tantas variables como bandas intervienen en el proceso), se considera el vector de medias y la matriz de varianza-covarianza entre pares de categorías. La fórmula de cálculo se sintetiza de la forma siguiente:

$$\text{Div}_{AB} = 0{,}5\ Tr\left\{(V_A - V_B)\ (V_B^{-1} - V_A^{-1})\right\} + \\ + 0{,}5\ Tr\left\{(V_A^{-1} + V_B^{-1})\ (M_A - M_B)\,(M_A - M_B)^T\right\} \qquad \{7.31\}$$

donde Div_{AB} indica la medida de la divergencia entre las categorías A y B; Tr, se refiere a la traza o suma de los elementos de la diagonal de la matriz indicada [ ]; V_A y V_B son las matrices de varianza-covarianza de las categorías A y B; M_A y M_B son los vectores de medias correspondientes a las mismas categorías y bandas, y T indica la matriz transpuesta de la indicada entre paréntesis. Cuanto mayor sea el valor de la divergencia, mayor también la separabilidad entre clases, basada, lógicamente, sobre las bandas que se han considerado en su cálculo.

El problema fundamental de esta medida es que no se satura. Si se pretende relacionar la divergencia con la exactitud de la posterior clasificación, esto implica que la exactitud aumentaría constantemente al aumentar el número de bandas utilizadas para clasificar, lo cual no es muy realista. Por esta razón, se recomienda acotar este valor en unos márgenes conocidos, definiéndose la divergencia transformada como (Kumar, 1977, #360):

$$DT_{AB} = c\ (1 - \exp\ (- Div_{AB}/8)) \qquad \{7.32\}$$

donde c indica el valor máximo de la divergencia, señalándose habitualmente un valor de 2.000, aunque algunos autores recomiendan utilizar un valor de 100 (Mather, 1998), para que los resultados puedan interpretarse como porcentajes.

La divergencia también se ha empleado como medida para seleccionar el con-

junto de bandas que proporciona la mejor separación entre clases. En este sentido se calcula un valor promedio de divergencia, de acuerdo a (Richards y Xia, 1999):

$$\overline{div} = \sum_{i=1,m} \sum_{j=1,m} p(w_i)p(w_j)Div_{i,j} \qquad \{7.33\}$$

donde $p(w_i)$ y $p(w_j)$ indican las probabilidades *a priori* de las clases i y j, m el número de clases, y $Div_{i,j}$ es el valor de la divergencia entre esas clases. La divergencia promedio se calcula para cualquier combinación de m bandas, siendo la combinación ideal la que maximiza el valor global de separación entre clases (Jensen, 1996, pp. 220-224). Además de la divergencia, se han propuesto otras medidas de separabilidad, como la distancia de *Bhattacharyya* o de *Mahalanobis* (Thomas *et al.*, 1987).

La tabla 7.8 incluye el cálculo de la divergencia transformada (en este caso, escalada de 0 a 2.000) para las clases seleccionadas en nuestro ejemplo. Esta tabla nos permite confirmar las valoraciones previamente efectuadas sobre posibles confusiones entre clases. La clase más nítida es el agua, fácilmente separable del resto de las cubiertas por su peculiar comportamiento espectral. Los suelos descubiertos ofrecen una notable confusión con la clase urbana, como ya comentamos en los gráficos de dispersión. También se observan problemas entre las clases matorral-urbano y pinar-encinar con cultivos.

Como antes indicamos, la divergencia también puede utilizarse para indicar la combinación idónea de bandas para la clasificación. En nuestro caso, se calculó para todas las combinaciones de una, dos, tres y cuatro bandas, utilizando como bandas de entrada las corregidas de reflectividad por el método de Chávez, como estamos haciendo en este epígrafe. La primera banda seleccionada por este método es la ETM-5 (SWIR), que ofrece la mayor divergencia promedio a las categorías que hemos seleccionado. Las dos bandas mas discriminantes serían la 5 y la 3 (R, SWIR); mientras se seleccionan la 2, 4 y 5 (R, IRC y SWIR) para el caso de tres bandas. Éste sería el espacio ideal de separación considerando las características espectrales del sensor ETM+.

Como principal conclusión de este epígrafe, parece deducirse que el análisis de las estadísticas de entrenamiento resulta muy conveniente para reflexionar sobre la conveniencia de la leyenda empleada, del tipo de información disponible, o del método emprendido para conseguir los resultados deseados. Salvado este análisis, puede iniciarse la fase de clasificación propiamente dicha, en la que no deben de producirse resultados muy distintos a los deducidos a partir de este previo estudio.

TABLA 7.8. *Divergencia transformada entre las categorías de la imagen Torre100*

	Urbano	*Pastizal*	*Matorral*	*Pinar-encinar*	*Agua*	*Suelo*
Pastizal	2.000					
Matorral	1.998	1.999				
Pinar-encinar	2.000	2.000	2.000			
Agua	2.000	2.000	2.000	2.000		
Suelo	1.942	2.000	1.990	2.000	2.000	
Cultivo	2.000	2.000	2.000	1.993	2.000	2.000

2.3. Fase de asignación

En esta fase se trata de adscribir cada uno de los píxeles de la imagen a una de las clases previamente seleccionadas. Esta asignación se realiza en función de los ND de cada píxel, para cada una de las bandas que intervienen en el proceso. Fruto de esta fase será una nueva imagen, cuyos ND expresen la categoría temática a la que se ha adscrito cada uno de los píxeles de la imagen original.

En este capítulo se tratan los criterios más empleados para realizar este proceso, en el contexto de las aplicaciones de la teledetección. Desde un punto de vista estadístico, todos ellos definen un área de dominio, en torno al centro de cada categoría a discriminar, mediante un conjunto de funciones discriminantes. Estas ecuaciones pueden considerarse, por tanto, como las fronteras que definen cada categoría. El píxel será asignado a una clase *i*, si sus ND se encuentran dentro del área de dominio señalado para dicha clase.

Los criterios más comunes para establecer estas fronteras estadísticas entre clases son: 1) mínima distancia, por el cual el píxel se asigna a la clase más cercana espectralmente; 2) paralelepípedos, que permite señalar al usuario unos umbrales de dispersión espectral asociados a cada clase, y 3) máxima probabilidad, en donde el píxel se asigna a aquella clase con la que posee mayor probabilidad de pertenencia. Frecuentemente se suelen agrupar en métodos no paramétricos, los dos primeros, y paramétricos, el último, en razón de si asumen o no que los ND en cada categoría se distribuyen normalmente. A continuación se describen, con más detalle, cada uno de estos criterios.

2.3.1. *Clasificador de mínima distancia*

El criterio más sencillo para asignar un píxel a una de las categorías consiste en incluirlo en la más cercana; esto es, en aquélla que minimice la distancia entre ese píxel y el centroide de clase. Lógicamente, no se trata de una distancia geográfica, sino espectral, consecuencia de comparar los ND de cada píxel con los del centro de las distintas categorías, para todas las bandas que intervienen en el análisis (fig. 7.41).

Pueden considerarse varias formas de medir esa distancia espectral entre píxeles y clases. La más empleada, en este sentido, es la distancia euclidiana:

$$d_{x,A} = \sqrt{\sum_{i=1,m} (END_{x,i} - \overline{\mathrm{ND}}_{A,i})^2} \qquad \{7.34\}$$

donde $d_{x,A}$ es la medida de la distancia entre el píxel *x* y la categoría *A*; $\mathrm{ND}_{x,i}$ el valor correspondiente al píxel a clasificar en la banda *i*, y el valor medio de esa categoría en la misma banda. Tras calcular esta medida para todas las categorías, puede obtenerse el valor $d_{x,A}$ más pequeño, asignando el píxel *x* a esa categoría. Como se trata de realizar comparaciones entre distancias, la fórmula anterior puede simplificarse eliminando la raíz cuadrada, ya que si un píxel es más cercano a una categoría por la distancia lineal (hipotenusa de sus valores espectrales), también lo será por la suma del cuadrado de sus catetos.

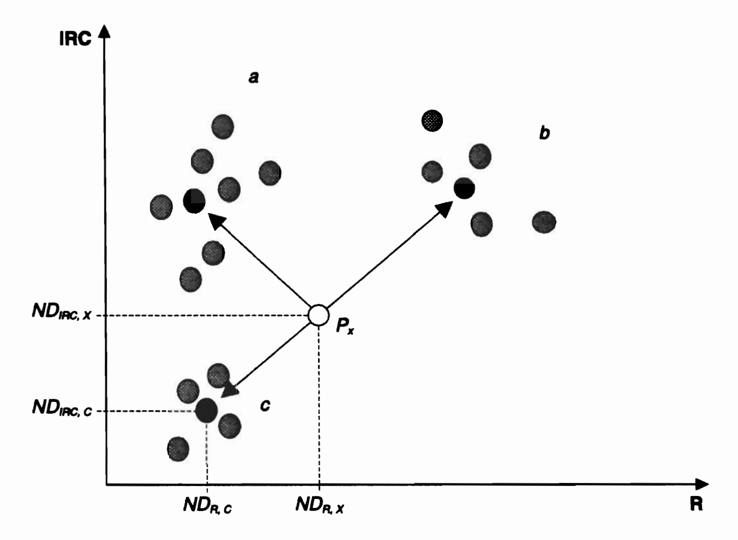


FIG. 7.41. *Algoritmo de mínima distancia.*

Este algoritmo es bastante sencillo y rápido de ejecutar, y puede ofrecer buenos resultados cuando no se observe un gran solape entre categorías. Puesto que siempre existe una clase más cercana, no deja lugar a píxeles sin clasificar, incluso aunque éstos se alejen notablemente del centro de clase. Esto puede provocar errores de comisión importantes, sobre todo cuando no se incluya en la leyenda alguna categoría claramente presente en la imagen.

La distancia que calcula este algoritmo es lineal; además, no considera la dispersión de cada categoría o la correlación que exista entre las bandas. Tiende, por tanto, a delimitar grupos circulares de radio proporcional a la situación de cada categoría.

Algunos autores han propuesto modificaciones en el cálculo de la distancia, de tal forma que se considere la varianza de las clases (Lo *et al.*, 1986; Schowengerdt, 1983). De una u otra forma, el método de mínima distancia se ha empleado con frecuencia en aplicaciones temáticas, especialmente cuando el área de estudio no presentaba una gran complejidad. Una excepción interesante a esta idea general es su aplicación exitosa a la cartografía de paisajes gallegos (López Vizoso, 1987).

2.3.2. *Clasificador de paralelepípedos*

En este método, el usuario fija un área de dominio para cada categoría, teniendo en cuenta sus valores de centralidad y dispersión. Posteriormente, un píxel es asignado a dicha clase si sus ND están dentro de ese área de dominio, en todas las bandas consideradas (fig. 7.42). Esquemáticamente, el píxel *x* será asignado a la clase *A* si sus ND en las distintas bandas ($ND_{x,k}$) están incluidos en el área de dominio de esa clase:

$$\overline{ND}_{A,i} - R_{A,i} \leq ND_{x,i} \leq \overline{ND}_{A,i} + R_{A,i} \qquad \{7.35\}$$

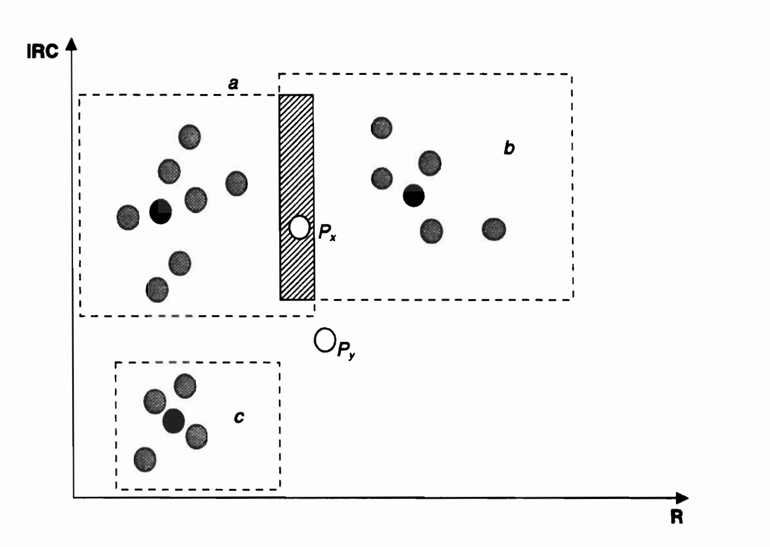


FIG. 7.42. *Clasificador de paralelepípedos.*

para todo i, variando entre 1 y el número de bandas. $R_{A,\,i}$ indica el rango de dispersión señalado para la categoría A en cada banda i.

En suma, un píxel es asignado a una determinada clase si sus ND se encuentran a menos de una determinada distancia del centro de esa clase. Esa distancia se fija por el intérprete, aunque suele identificarse con la desviación típica, o con un múltiplo suyo. También pueden emplearse otros criterios como la desviación media, desviación intercuartílica o rango de la categoría. En cualquier caso, conviene considerar que cuanto mayor sea ese umbral, mayor también el número de píxeles incluidos en esa clase, pero también más grande el riesgo de confusiones con categorías vecinas. De igual forma, un valor pequeño garantiza mayor fiabilidad en las asignaciones, pero supone un mayor número de píxeles sin clasificar.

Este criterio de asignación tiende a delinear unos polígonos multidimensionales de lados paralelos, de ahí su nombre, en torno al centro de cada categoría. Es un algoritmo bastante rápido de ejecutar, puesto que sólo requiere operaciones lógicas sencillas (del tipo IF ... THEN...). Por esta rapidez, se ha utilizado con frecuencia como primer acercamiento a la variabilidad de las distintas categorías (Miller y Williams, 1978). Asimismo, se ha utilizado para lograr una primera estratificación de la imagen, aislando las categorías más singulares, para aplicar posteriormente otro criterio de asignación sobre los píxeles más problemáticos (Núñez de las Cuevas *et al.*, 1983).

Los principales problemas de este método parten de su misma concepción. El diseño de áreas de dominio puede implicar, por un lado, que haya píxeles en zonas comunes a dos o más categorías, y, por otro, que algunos píxeles queden sin clasificar (fig. 7.42). Respecto al primer problema, el solape entre paralelepípedos supone que un píxel pueda asignarse a dos categorías. Si el programa no cuenta con otro criterio, lo incluirá en la primera que cumpla los requisitos marcados en {7.35}. En consecuencia, algo tan intrascendente como el orden en el que se produce la asignación tiene una importante repercusión sobre los resultados. Algunos autores han propues-

to modificar el criterio de asignación para estas áreas en conflicto, bien introduciendo la regla de mínima distancia (Mather, 1998), bien ajustando interactivamente las fronteras entre clases (Lillesand y Kiefer, 2000), bien creando clases mixtas.

Respecto a los píxeles sin clasificar, la solución pasa por ampliar paulatinamente el rango de dispersión, estableciendo un equilibrio entre los píxeles no clasificados y los solapes entre clases vecinas. También conviene, en estos casos, repasar la definición espectral de las categorías, puesto que la presencia de píxeles sin asignación es indicio de clases espectrales mal definidas o no incluidas en la leyenda de trabajo.

2.3.3. *Clasificador de máxima probabilidad*

Este método considera que los ND en el seno de cada clase se ajustan a una distribución normal. Esto nos permite describir esa categoría por una función gausiana, a partir de su vector de medias y matriz de varianza-covarianza. Esto nos permite calcular la probabilidad de que un píxel pertenezca a esa categoría, conociendo sus valores en las distintas bandas que empleamos para clasificar. El cálculo se realiza para todas las categorías que intervienen en la clasificación, asignando el píxel a aquélla que maximice la función de probabilidad. Este criterio de clasificación es algo más complejo que los anteriores y requiere mayor volumen de cálculo, pero es el más empleado en teledetección, por su robustez y por ajustarse con más rigor a la disposición original de los datos.

Para comprender mejor su funcionamiento, puede ser útil poner un sencillo ejemplo ideado por Swain y Davis (1978). Supongamos que se cuenta con dos pares de dados, uno normal (caras numeradas de 1 a 6) y otro con un par de puntos adicionales en cada cara (numerados de 3 a 8). Conociendo el valor de una tirada, el problema sería estimar de cuál de los dos pares de dados procede. Un criterio razonable de asignación sería calcular la probabilidad de que esa tirada se haya realizado con los dados normales o con los modificados, asignando la tirada desconocida al par de dados más probable. Por ejemplo, si obtenemos un tirada de 7, la probabilidad de haber tirado con los dados normales es 6/36 (6 casos favorables, frente a los 36 posibles). Para los dados aumentados, la probabilidad es menor, 2/36, por lo que la tirada se asigna al par de dados normal. El mismo criterio podría seguirse para decidir la asignación de cualquier otra puntuación. Basta construir las funciones de probabilidad asociadas con cada par de dados. Para el par normal, tendríamos una distribución centrada en el valor 7 (máxima probabilidad), con un mínimo de 2 y un máximo de 12. Para el par modificado, el valor más probable se encontraría en 11, situándose la curva entre 6 y 16 (fig. 7.43*a*). A partir de esta gráfica, se observa que la probabilidad de haber usado los dados normales es mayor que la de haber usado los aumentados si obtenemos una tirada inferior a 8, es menor si la tirada superó 10 y es idéntica si la tirada fue 9. En definitiva, la frontera para asignar la tirada a un par de dados u otro se establece en la intersección entre sus respectivas funciones de probabilidad.

Esto no significa, obviamente, que no pueda producirse una tirada mayor a 9 con el par de dados normal, ni inferior a 9 con el aumentado. En otras palabras, la regla no es completamente certera, pero sí bastante razonable. Sólo es plenamente

FIG. 7.43. *Distribución de probabilidad para las tiradas de un par de dados normal y otro con dos puntos más en cada cara* (a). *Efecto si duplicamos las puntuaciones en el dado normal* (b).

fiable para valores superiores a 12 o inferiores a 6, puesto que ahí no existe solape entre categorías. En suma, si existe conflicto natural entre clases, no es posible separarlas con total fiabilidad. En suma, los errores serán tanto mayores cuanto mayor sea el solape entre las funciones de probabilidad.

Extendiendo el ejemplo propuesto por Swain y Davis, supongamos que al par de dados normal le modificamos alguna cara, para que las puntuaciones vayan de dos a cinco, en lugar del 1 y el 6, repitiendo las puntuaciones 3 y 4. Esto no implicaría modificar el valor central de la distribución, que seguiría siendo 7. Sin embargo, sí cambia la anchura de la curva, las puntuaciones están más cercanas a la media, hay mayor homogeneidad. Eso conlleva que las asignaciones que se hagan a partir de la distribución de probabilidad serán más seguras. El punto de corte sigue estando en 9, pero a partir de ese valor la probabilidad de encontrar puntuaciones superiores con el par de dados normal se reduce drásticamente (fig. 7.43*b*). Esto im-

plica que a mayor homogeneidad, o si se prefiere menor varianza, la discriminación de categorías resulta más certera.

El ejemplo puede aplicarse fácilmente al contexto de la clasificación digital. El par de dados a estimar puede sustituirse por las distintas categorías que quieren discriminarse, y las tiradas por los ND de los píxeles a clasificar. En el caso de los dados, podemos calcular *a priori* la probabilidad de pertenencia asociada con cada tirada, pues conocemos la distribución de todas las posibles tiradas. Para el caso de la clasificación de categorías temáticas es preciso estimar esa distribución de probabilidad para cada categoría, a partir de las medidas realizadas sobre las áreas de entrenamiento. Con este fin, se considera que los ND en el seno de cada clase se distribuyen normalmente, por lo que basta conocer la media y la desviación típica de cada categoría para calcular la probabilidad asociada con un determinado ND. En el caso de trabajar con una sola banda, podríamos calcular esa probabilidad de acuerdo a:

$$p(x / A) = \frac{1}{\sqrt{2\pi\sigma_A^2}} \exp\left\{-(\mathrm{ND}_x - \overline{\mathrm{ND}}_A)^2 / 2\sigma_A^2\right\} \qquad \{7.36\}$$

Esto es, la probabilidad de que un píxel x, definido por un determinado NDx, pertenezca a la clase A, puede calcularse a partir de la media (ND_A) y la varianza (σA^2) de esa clase. Una vez determinada la probabilidad de pertenencia al resto de las categorías que intervienen en la clasificación, ese píxel será asignado a la clase A sólo si:

$$p\ (x/A) \geq p\ (x/B) \qquad \{7.37\}$$

para todo $A \neq B$, variando B desde 1 hasta c, siendo c el número de categorías.

Con el propósito de agilizar el cálculo, puede transformarse la fórmula anterior en una función lineal, mediante el empleo de logaritmos (Schowengerdt, 1983):

$$\ln p(x / A) = -0{,}5 \ln(2\pi) - 0{,}5 \ln \sigma A^2 - \left\{(\mathrm{ND}_x - \overline{\mathrm{ND}}_A)^2 / 2\sigma A^2\right\} \qquad \{7.38\}$$

La expresión puede simplificarse aún más si eliminamos el primer término ($-0{,}5 \ln (2\pi)$), por cuanto nos interesa sólo un cálculo de la probabilidad relativo a las distintas clases, y ese valor es una constante para todas ellas. Por la misma razón, no resulta necesario reconvertir a antilogaritmos el valor calculado, ya que si el logaritmo de la probabilidad es mayor en una categoría que en otra, también lo será su antilogaritmo. Por último, el segundo término ($0{,}5 \ln \sigma_A^2$) puede calcularse inicialmente para cada categoría, quedando así reducido el cálculo, para cada píxel, a la última expresión.

Volviendo al ejemplo anterior, podría también ocurrir que contáramos con dos pares de dados normales y sólo con uno aumentado. En este caso, no sólo tendremos que considerar el valor de la tirada para identificarla como perteneciente a uno u otro tipo de dados, sino también la probabilidad *a priori* de que aparezca una ti-

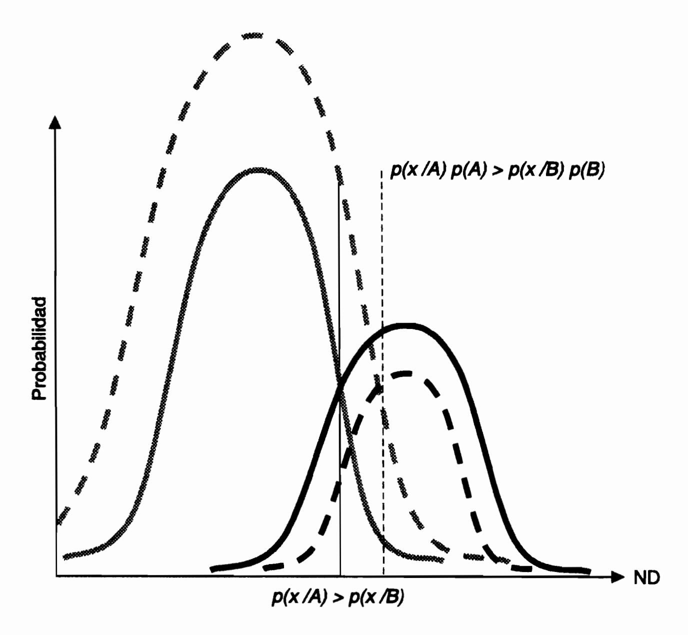


FIG. 7.44. *Efecto de considerar la probabilidad a priori. En línea discontinúa las nuevas funciones de probabilidad y la intersección entre las dos categorías.*

rada de cada par de dados, en función de su número. En muchas aplicaciones de la teledetección también se produce este fenómeno. Algunas de las categorías cuentan con mayor extensión superficial, y, por tanto, presentan mayor probabilidad de albergar píxeles desconocidos. Al considerar la probabilidad *a priori* de cada categoría $p(A)$, se introduce un nuevo factor en el criterio de decisión arriba enunciado {7.37}. De esta forma, un píxel pertenece a la clase A, si:

$$p\ (x/A)\ p\ (A) \geq p\ (x/B)\ p\ (B) \qquad \{7.39\}$$

para todo $A \neq B$, donde I (x/A) indica la probabilidad de que un píxel x con un ND determinado, pertenezca a la clase A, y $p\ (A)$ la probabilidad *a priori* de que un píxel cualquiera se incluya en esa clase.

La figura 7.44 expresa gráficamente el efecto de introducir esta opción. El punto de corte entre las distribuciones de probabilidad, se desplaza hacia un lado u otro del original, en función del valor de la probabilidad *a priori*. Recuérdese que la intersección entre curvas marca la frontera en el área asignada a cada categoría, por lo que este factor puede modificar significativamente los resultados.

Con ser de gran interés, el empleo de este parámetro resulta bastante complejo, especialmente para establecer un criterio riguroso que permita estimar los valores de probabilidad *a priori* para cada clase. Un posible criterio sería conceder a cada categoría una probabilidad equivalente a la superficie que ocupa en la zona de estudio. Esto requiere, naturalmente, contar con un inventario previo, que raras veces está disponible. Indirectamente, sin embargo, puede calcularse la importancia superficial de cada clase mediante trabajos de campo, datos auxiliares o empleando los resultados

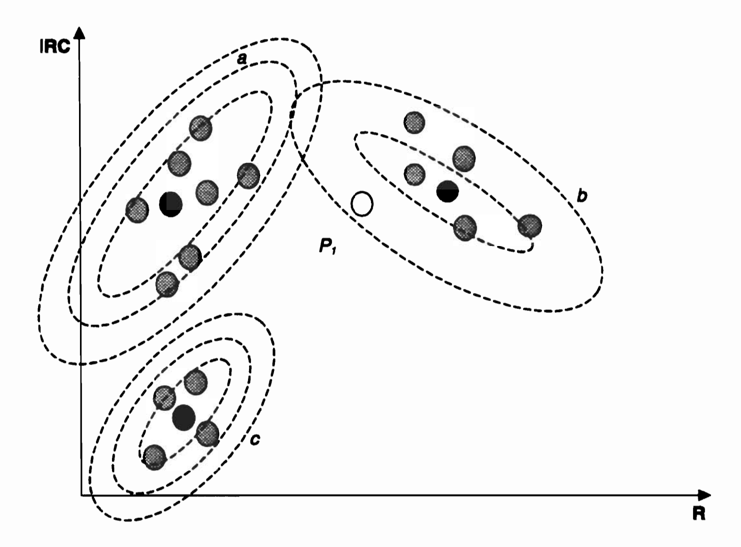


FIG. 7.45. *Extensión a dos bandas del algoritmo de máxima probabilidad.*

de una clasificación previa. Por último, también puede optarse por obviar este criterio, simplemente otorgando la misma probabilidad *a priori* a todas las categorías.

El interés de ponderar la probabilidad de cada clase se ha puesto en evidencia por distintos autores (Strahler, 1980). En aquellas ocasiones en las que se cuenta con un criterio sólido para estimar esas probabilidades, se ha comprobado que mejoran la asignación significativamente (Mergerson, 1981).

Hasta el momento, hemos analizado el criterio de máxima probabilidad para el caso de una sola banda. Lo habitual será, no obstante, que se empleen varias bandas para la clasificación, por lo que resulta preciso extender a varias dimensiones lo hasta aquí comentado. Para el caso de dos bandas, los límites de las categorías tienen una forma elipsoidal (fig. 7.45). Cada una de estas elipses define un determinado nivel de probabilidad asociado a una categoría. Cuanto mayor sean las zonas de solape entre ellas, tanto mayor el riesgo de confusión mutua.

Con más de dos dimensiones, no es posible representar gráficamente este criterio de clasificación. Basta extender la fórmula de la probabilidad normal arriba apuntada:

$$p(x / A) = (2\pi)^{-m/2} \left|V_A\right|^{-0,5} \exp\left\{-0,5(M_x - M_A)^T V_A^{-1} (M_x - M_A)\right\} \qquad \{7.40\}$$

donde m indica el número de bandas, $|V_A|$ la determinante de la matriz de varianza-covarianza para la clase A; M_x el vector de ND asociado con el píxel x; M_A, el vector de ND medios de la categoría A, y los superíndices T y -1, la transpuesta y la inversa de las matrices a las que afectan, respectivamente. Esta fórmula también puede simplificarse mediante el uso de logaritmos:

$$\ln p(x / A) = (-0,5 \ln V_A) - (0,5(M_x - M_A)^T V_A^{-1} (M_x - M_A)) \qquad \{7.41\}$$

una vez suprimidos los términos constantes de la fórmula anterior.

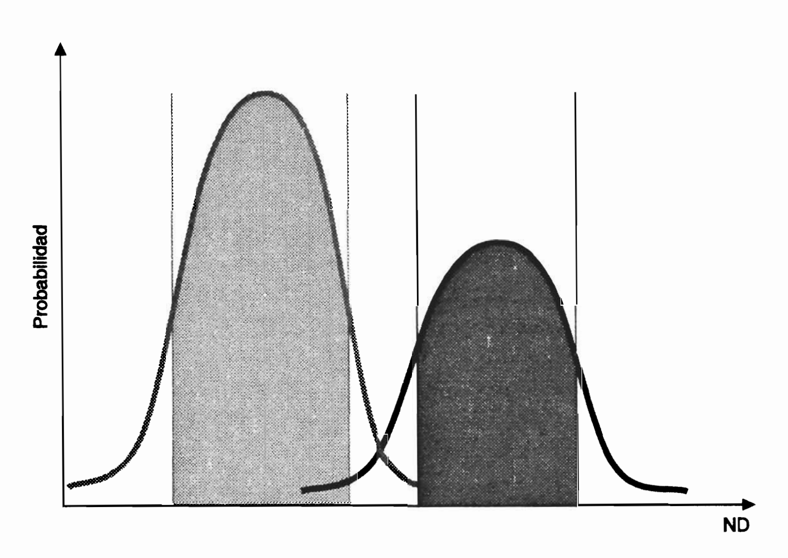


FIG. 7.46. *Efecto de considerar la probabilidad a posteriori.*

Una vez que se culmine la asignación de los píxeles de la imagen, es posible establecer unos umbrales de probabilidad para cada categoría, de tal forma que se rechacen aquellos píxeles con una probabilidad de pertenencia muy baja (fig. 7.46). Este proceso, posterior a la clasificación propiamente dicha, pretende evitar aquellos píxeles con un grado de asociación muy bajo, reduciendo así los errores de comisión debidos a una mala definición espectral de algunas categorías. Sin embargo, aplicar este criterio supone la aparición de píxeles no clasificados. Si su número es considerable, convendrá retornar a la fase de entrenamiento, con objeto de deducir nuevas categorías o perfeccionar la definición de las ya existentes. En la figura 7.47 se incluye un ejemplo de la aplicación de este criterio, en este caso a la imagen Barrax99. Se ha utilizado un criterio bastante exigente de probabilidad a posteriori, que elimina la asignación a los píxeles con menos del 95 % de probabilidad de pertenencia. A consecuencia, la mayor parte de la imagen aparece como no clasificada, pero las zonas sí asignadas identifican las más similares a las características de las áreas que se utilizaron para el entrenamiento.

El criterio de máxima probabilidad asume que las categorías presentan una distribución normal, requisito que ha sido comprobado en numerosos estudios. No obstante, aún en el caso de que las bandas de entrada no cumplan este criterio, algunos autores han mostrado que los resultados siguen siendo bastante consistentes (Swain y Davis, 1978).

Para la imagen Torre100, la aplicación del criterio de máxima probabilidad permitió generar una clasificación bastante atinada (fig. 16*). Las principales confusiones se observaron entre las categorías urbanas y los suelos descubiertos, si bien las primeras se discriminan razonablemente bien, tanto en los cascos de los municipios, como en sus áreas residenciales. Los matorrales y encinares tienen una clara yuxtaposición, mientras la categoría pinar-encinar en realidad sólo se refiere a los pinares de *P. sylvestris* situados en las zonas de mayor relieve. Los cultivos se ciñen exclusivamente al valle del Jarama, en el borde oriental de la imagen, mientras los pasti-

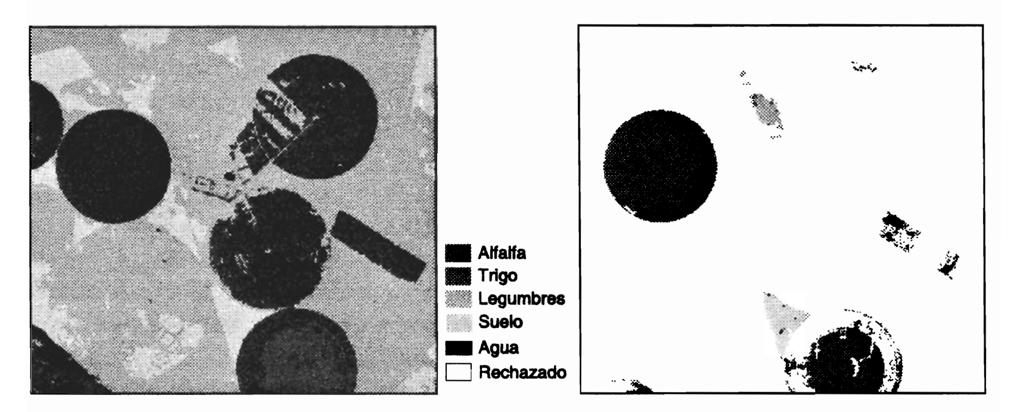


FIG. 7.47. *Clasificación de cultivos en la imagen Barrax99: original y después de rechazar los píxeles < 95 % de probabilidad.*

zales ocupan la mayor parte de los fondos de valle en los municipios de Soto del Real, Miraflores y Guadalix. Por su parte, los matorrales-encinares se localizan en las laderas del cerro de San Pedro, en el centro de la imagen y en el piso inferior de la Sierra, al norte y oeste de la zona de estudio. En este último sector, se confunden en ocasiones con caducifolios que aún no han echado la hoja.

Comparando estos resultados con los generados de la clasificación no supervisada, a partir del algoritmo ISODATA (con 18 clases finales, de un máximo de 20 previamente fijado), se pudo observar que se separaban mejor algunas clases informacionales, como las correspondientes a pinar y encinar, bastante solapadas en la clasificación de máxima probabilidad, mientras el matorral se ciñó mejor a las áreas que realmente ocupaba. La categoría urbana, por el contrario, apareció un poco más difuminada en la clasificación no supervisada, confundida con suelos en el caso de los núcleos más densos. No todas las áreas residenciales-ajardinadas aparecían, pero sí una buena parte de ellas. También se realizó una buena discriminación de los suelos descubiertos y del agua.

2.3.4. *Clasificadores en árbol*

Si bien el clasificador de máxima probabilidad es el más ampliamente utilizado en clasificación digital de imágenes, sus limitaciones en cuanto al cálculo y la exigencia de contar con distribuciones normales hacen que se hayan buscado criterios alternativos, menos sensibles a esos requisitos.

Uno de los métodos más sencillos, pero también más eficientes de clasificación alternativa es el denominado clasificador en árbol *(decision tree classifier)*. La idea de fondo consiste en discriminar secuencialmente cada una de las categorías, basándose bien en valores espectrales de la imagen, bien en variables texturales, temporales o en información auxiliar (suelos, MDE, etc.). Para cada clase se establecen unas reglas dicotómicas de interpretación, que permiten concentrar la discriminación de cada clase a partir de las variables en que mejor se discrimina, en lugar de utilizar todas indistintamente. Por ejemplo, pueden reconocerse las láminas de agua por una reflectividad inferior a un cierto umbral en el SWIR, o la

vegetación por una combinación de cierto umbral en el VIS e IRC. Inicialmente, estos algoritmos en árbol se diseñaban únicamente con bandas espectrales, pero más recientemente emplean también variables auxiliares, como mapas de suelos o modelos digitales de elevación (Friedl y Brodley, 1997; Friedl *et al.*, 1999; Stroppiana *et al.*, 2003)

Bajo ese punto de vista, el clasificador en árbol puede considerarse como un sencillo ejemplo de sistema experto (Skidmore, 1989), tan extendido en los últimos años en el marco de las denominadas técnicas de inteligencia artificial. Puede considerarse que un sistema experto está formado por un conjunto de reglas que permiten al algoritmo tomar una serie de decisiones en función de los valores que observa en la imagen y/o en información auxiliar de la misma zona. Esas reglas se introducen en forma de operadores lógicos condicionales, del tipo IF... THEN..., que intentan simular la toma de decisiones que realiza un intérprete (Richards, 1993, cap. 12). Por ejemplo, podríamos distinguir la vegetación forestal de la herbácea a parte de asociar criterios de tono y textura, utilizando una regla del tipo siguiente:

$$\text{IF } ND_{IRC} / ND_R > 2 \text{ AND } \textit{Textura} = \text{Rugosa THEN } \textit{Bosque}$$

$$\text{IF } ND_{IRC} / ND_R > 2 \text{ AND } \textit{Textura} = \text{Lisa THEN } \textit{Prados}$$

el primer término lo podría tomar de una imagen óptica y la textura de una imagen radar de la misma zona. De forma similar se pueden introducir variables no obtenidas por teledetección, como cartografía temática, límites administrativos o MDE. El establecimiento de los criterios de decisión se realiza por un experto en el reconocimiento de cada categoría de interés, que conozca sus condiciones ambientales para la zona en la que se trabaja (Hansen *et al.*, 1996). Por ejemplo, para el reconocimiento de una especie forestal, serían relevantes el calendario fenológico, la situación topográfica, el tipo de litología asociado, o la rugosidad. Con este enfoque Skidmore (1989) realizó un inventario de eucaliptos en Australia, a partir de imágenes de satélite e información auxiliar. Este autor observó una mejora significativa en la clasificación, mediante el empleo de una tabla de probabilidades asociada a la ocurrencia del eucalipto en distintas variables auxiliares. También podrían incorporarse criterios temporales o espaciales, como sería la probabilidad de que un cierto cultivo suceda a otro o esté próximo a otro (Middelkoop y Janssen, 1991).

Los clasificadores en árbol se han utilizado en los últimos años con cierto éxito, tanto en la cartografía de especies forestales (Saura y San Miguel, 2001), como para asignar tipos de vegetación y cobertura del suelo, con especial relieve en aplicaciones de ámbito global (Friedl *et al.*, 1999; Stroppiana *et al.*, 2003).

Un sencillo ejemplo de clasificación en árbol sería el incluido en la figura 7.48. El criterio de decisión se basa en unas hipotéticas estadísticas de entrenamiento para una serie de clases de cobertura del suelo (tabla 7.9). En este caso, el análisis se realiza sobre cuatro bandas espectrales: V, R, IRC y SWIR, a las que se ha añadido información altitudinal extraída de un MDE. A partir de estos valores puede diseñarse un gráfico de dispersión espectral, considerando el rango como la media ± 2 desviaciones típicas. Con ayuda de este gráfico podemos diseñar un árbol de decisiones que nos permita separar las cinco categorías. El primer paso con-

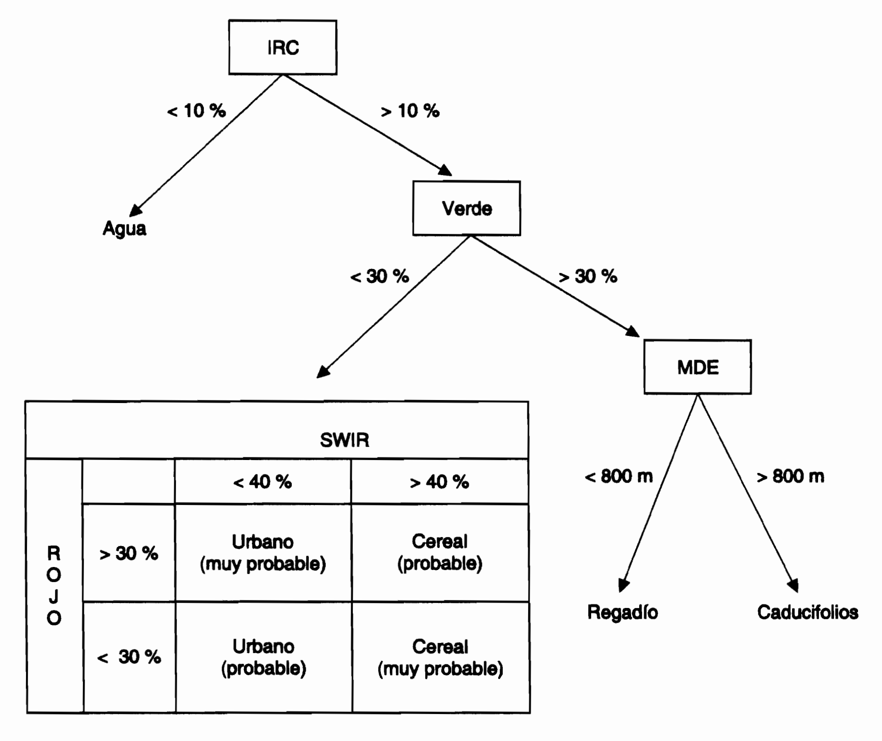


FIG. 7.48. *Ejemplo de clasificación en árbol.*

siste en separar los píxeles pertenecientes a la categoría más fácilmente discriminable, el agua. Para ello, se emplea el IRC, utilizando un umbral máximo de reflectividad del 10 %. Por tanto, los píxeles con una $\rho \leq 10$ en esa banda serán etiquetados como clase agua y extraídos de la imagen para evitar que intervengan en pasos sucesivos. Posteriormente se emplea la banda V para discriminar las clases regadío y caducifolios del resto, indicando como valor límite la ρ del 30 %. Con las categorías urbano y cereal es preciso realizar el ajuste en dos bandas, puesto que existe un cierto solape en todas ellas. Sin embargo, la separación es mayor en la banda del SWIR, señalando sobre ella un umbral del 40 % de ρ para la discriminación, completándolo con otro umbral del 30 % en la banda R. Finalmente, entre las clases caducifolios y regadío, bastante mezcladas espectralmente, utilizamos un criterio ba-

TABLA 7.9. *Medidas estadísticas para distintas cubiertas (reflectividad · 100)*

	X_{med}	*D. T.*	X_{med}	*D. T.*	X_{med}	*D. T.*	X_{med}	*D. T.*
Agua	13	3	12	2	8	2	3	2
Cereal	35	5	28	8	50	12	42	8
Regadío	14	5	19	4	60	10	14	2
Caducifolios	16	4	21	6	54	12	18	3
Urbano	42	7	36	5	48	10	34	7

sado en la altitud: asumiendo que en la zona sólo se dan cultivos en regadío por debajo de 800 m, utilizamos el modelo digital de elevaciones para establecer esta distinción.

Los problemas de clasificación reales son más complejos, pero también pueden enriquecerse notablemente las reglas de decisión. Una vez ajustadas adecuadamente, resulta un criterio muy rápido de clasificación, y permite introducir información auxiliar que resulta ajena a los clasificadores estadísticos convencionales (Friedl y Brodley, 1997). Un ejemplo más realista de clasificación en árbol es el algoritmo de detección de nubes propuesto por Saunders y Kriebel (1988), que tuvimos ocasión de analizar en el anterior capítulo, o los diversos algoritmos propuestos para detección de incendios activos (Martín *et al.*, 1999), o cartografía de área quemada (Chuvieco *et al.*, 2008).

2.3.5. *Clasificadores basados en el contexto espacial*

A lo largo de esta obra, hemos visto en diversas secciones que los rasgos espectrales de una determinada cubierta pueden presentar notables afinidades espectrales con otras, aunque posea componentes distintos. En consecuencia, para discriminar dos cubiertas puede ser necesario acudir a criterios no estrictamente espectrales, como serían los derivados de la variación espacial de cada píxel, en una cierta área de vecindad, o su situación respecto al resto de los píxeles que forman la imagen. Hasta aquí hemos analizado criterios de clasificación basados exclusivamente en los ND de cada píxel; en ocasiones, será preciso incorporar otros criterios de identificación, como son la textura o el contexto, afines a las relaciones espaciales entre los píxeles de la imagen, de modo similar a los utilizados en análisis visual (cap. 5).

La distinción entre los criterios de textura y contexto hace referencia al área que se considera en la medición de las relaciones espaciales (Gurney y Townshend, 1983). El primer concepto se relaciona con la variación espacial dentro de grupos contiguos de píxeles. El segundo, iría encaminado a medir las relaciones espaciales de cada píxel con el resto de la escena. Por simplificar las cosas, incluiremos ambos en el mismo epígrafe, ya que los dos están encaminados a aportar criterios espaciales a la clasificación de imágenes.

Podemos agrupar los métodos para introducir el contexto espacial en la interpretación digital en función de la fase de la clasificación en la que intervienen: antes, durante o después.

En el primer grupo estarían las técnicas que generan nuevas bandas que miden las propiedades espaciales de los píxeles de una imagen. Esas variables también pueden emplearse en la clasificación, de la misma forma que las bandas espectrales del sensor. El empleo de variables de textura resulta de especial interés en aplicaciones urbanas, ya que la clasificación de estas zonas resulta muy problemática por la gran variedad espectral de las superficies que las componen. Entre los criterios más interesantes está el propuesto por Gong y Howarth (1990). Estos autores pretendían discriminar áreas urbanas y rurales en la frontera rur-urbana de una ciudad canadiense. Para ello, incorporaron a la clasificación una imagen de «densidad de bordes», obtenida a partir del siguiente proceso: 1) aplicar un filtro laplaciano a la banda 1 de una

imagen SPOT-XS, 2) segmentar el resultado para dejar únicamente las fronteras entre cubiertas, 3) hallar la densidad de bordes a través de una ventana móvil (número de píxeles fronterizos dividido por número de píxeles en la ventana; en este caso de 25 × 25 píxeles), y 4) incorporar esa banda textural a la clasificación multibanda. Esa incorporación mejoró significativamente los resultados al reducir la confusión entre clases rurales y urbanas de similares características espectrales (p. ej., cultivos y jardines). También resulta de gran interés el clasificador de contexto propuesto por Moller-Jensen (1990), que parte de delimitar polígonos en una zona urbana mediante la localización automática de segmentos lineales (calles anchas o ríos). Los segmentos se clasifican de acuerdo a sus ND medios, así como a medidas de textura, contigüidad y distancia al centro de la ciudad.

El análisis del contexto previo a la clasificación puede abordarse también en la fase de entrenamiento. Un enfoque original, en este sentido, fue el denominado clasificador ECHO *(Extraction and Classification of Homogeneous Objects)*, propuesto en la primera etapa de la interpretación digital de imágenes (Ketting y Landgrebe, 1975), pero que se ha enfatizado mucho en los últimos años, ante el interés por la generación de clasificaciones más robustas especialmente. Este criterio proponía clasificar una imagen no a partir de píxeles, sino de polígonos formados por píxeles contiguos de similares características. En resumen, se trataba previamente de extraer objetos homogéneos, para luego ser asignados a las categorías de interés para el usuario. La delimitación de esas áreas homogéneas se basaba en criterios de similitud espectral y contigüidad. Tras localizar un pequeño grupo de píxeles con ND similares, el algoritmo iba incorporando progresivamente píxeles vecinos, siempre que estuvieran dentro de un criterio de homogeneidad señalado por el usuario (por ejemplo, a menos de una determinada distancia espectral). Cuando los píxeles vecinos no eran suficientemente homogéneos se identificaba una frontera o un área pequeña de distinta ocupación (isla). Estas zonas se clasificaban posteriormente de acuerdo a los criterios tradicionales, antes comentados. El proceso de crecimiento de las áreas continuaba hasta que se encontraban píxeles muy contrastados, con lo que el proceso se detenía. En este punto, la imagen aparecía segmentada en áreas homogéneas, aunque éstas aún no se hubieran asignado a ninguna categoría temática. La asignación se realizaba posteriormente calculando las estadísticas elementales de los píxeles incluidos en cada área, y aplicando sobre ellas uno de los criterios de asignación antes comentados. En ese punto, no eran asignados píxeles individuales sino las áreas completas, por lo que la posibilidad de discontinuidad espacial de los resultados tendía a reducirse considerablemente (Campbell, 1996; Hoffer y Swain, 1980).

El planteamiento pionero del clasificador ECHO se ha continuado en los últimos años, estudiándose las ventajas e inconvenientes que presenta la clasificación sobre píxeles *(per pixel classifiers)* o sobre polígonos *(per field classifiers)* (Aplin *et al.*, 1999). Estos últimos se denominan, más recientemente, clasificadores orientados a objetos. Estos clasificadores trabajan con aglomerados espaciales de píxeles, obtenidos mediante la segmentación de la imagen en función de las propiedades espaciales y espectrales de los píxeles. Esto implica cambiar la unidad de análisis, del píxel al polígono-mancha-parche, o como quieran denominarse esos agregados espaciales. Los polígonos se obtienen por una segmentación espectro-espacial de la imagen, que pretende definir grupos de píxeles espectralmente similares y contiguos

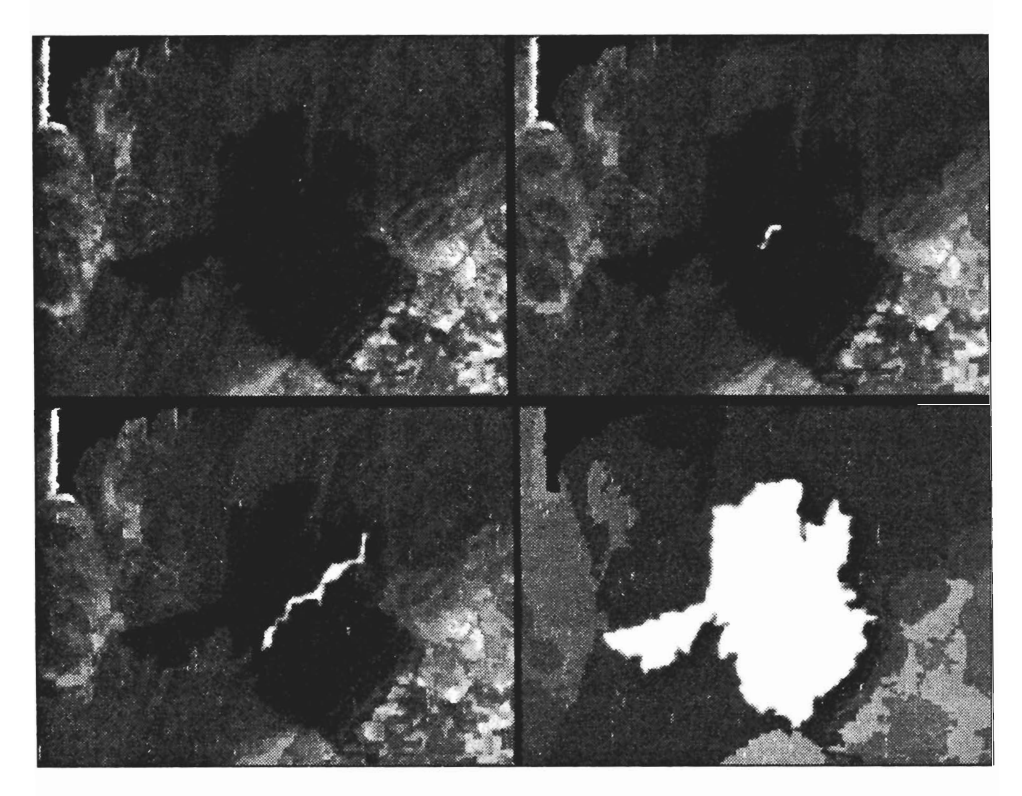


FIG. 7.49. *Segmentación con diversos niveles de detalle.*

(Zhang *et al.*, 2005). El proceso es especialmente idóneo para imágenes de alta resolución espacial, que de otro modo ofrecerían un notable ruido para la clasificación temática (Arroyo *et al.*, 2006; Gitas *et al.*, 2004; Schiewe *et al.*, 2001). Se han propuesto diversos criterios para realizar esa segmentación previa de la imagen, siendo los más habituales los que parten de reducir la resolución radiométrica de la imagen, aplicando posteriormente algún criterio de agregación espacial basado en la adyacencia (Lobo, 1997). Una vez que se han definido esos objetos espectro-espaciales, el resto de la clasificación se realiza con ellos: se seleccionan polígonos, en lugar de píxeles, para entrenar, mientras la asignación se hace con el polígono completo. Como es lógico, los resultados resultan mucho más homogéneos espacialmente que los obtenidos mediante la clasificación convencional.

La figura 7.49 incluye un ejemplo de segmentación para una imagen próxima al núcleo de Torrelaguna, afectada por un incendio forestal en 2002. La segmentación se ha realizado con varios niveles de detalle, aplicando criterios más o menos rígidos para generar polígonos. Esto permite delimitar polígonos más pequeños o más grandes, según reduzcamos o ampliemos los parámetros de control para definir la homogeneidad entre objetos.

El segundo grupo de clasificadores de contexto refiere a aquellos que incorporan este criterio en el propio algoritmo de asignación. Se trata, en términos sencillos, de realizar la asignación de un determinado píxel de la imagen no sólo a partir

de sus ND, sino también de los correspondientes a los píxeles vecinos. Una manera concreta de aplicar este criterio sería incorporar alguna variante de la vecindad espacial a alguno de los criterios de clasificación que vimos anteriormente. Por ejemplo, en el caso del algoritmo de máxima probabilidad puede considerarse la probabilidad de asignación de los píxeles vecinos (Richards, 1993):

$$p'(x / c_i) = \frac{p(x / c_i) q(x / c_i)}{\sum_{i=1,m} p(x / c_i) q(x / c_i)} \qquad \{7.42\}$$

donde $p(x/c_i)$ indica la probabilidad de que el píxel x pertenezca a la categoría c_i, para todas las categorías m y una función de vecindad, definida por el usuario, que habitualmente está relacionada con la distancia. Éste o similares criterios se han empleado con buenos resultados en distintas clasificaciones temáticas (Danjoy y Sadowski, 1978; González y López, 1991).

También puede introducirse el contexto para reconocer objetos mediante el contraste espectral que presentan respecto a cubiertas circundantes. Por ejemplo, puede introducirse la diferencia de temperatura entre un incendio activo y el promedio de una ventana regional, que permita estimar la temperatura de las zonas que no arden (Giglio *et al.*, 2003), o la diferencia de vigor vegetal entre zonas recientemente deforestadas y los bosques tropicales circundantes (Souza *et al.*, 2005). Los criterios de contexto se emplean también con bastante frecuencia en los algoritmos para reconocer nubes (Khlopenkov y Trishchenko, 2007; Latifovic *et al.*, 2005), o áreas quemadas (Chuvieco *et al.*, 2008; Chuvieco *et al.*, 2008; Pu *et al.*, 2007; Riaño *et al.*, 2007). La figura 7.50 ilustra un ejemplo del interés de estos criterios, en este caso para la detección de áreas quemadas en bosque boreal. En la primera fase (semillado) se retienen únicamente los píxeles más claramente quemados, que se utilizan en la segunda para refinar la delimitación de las áreas quemadas mediante criterios de similitud espectral y distancia.

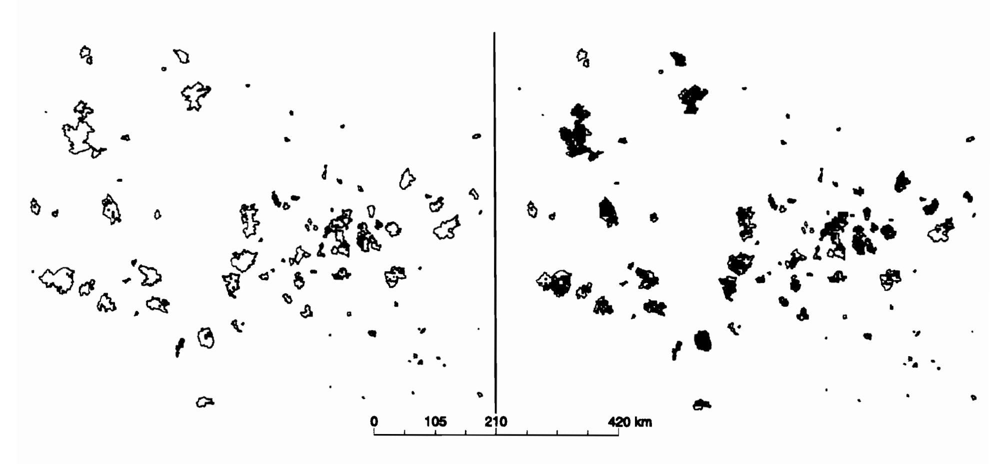


FIG. 7.50. *Variaciones en la clasificación de áreas quemadas entre emplear o no los criterios de contexto (Chuvieco* et al., *2008).*

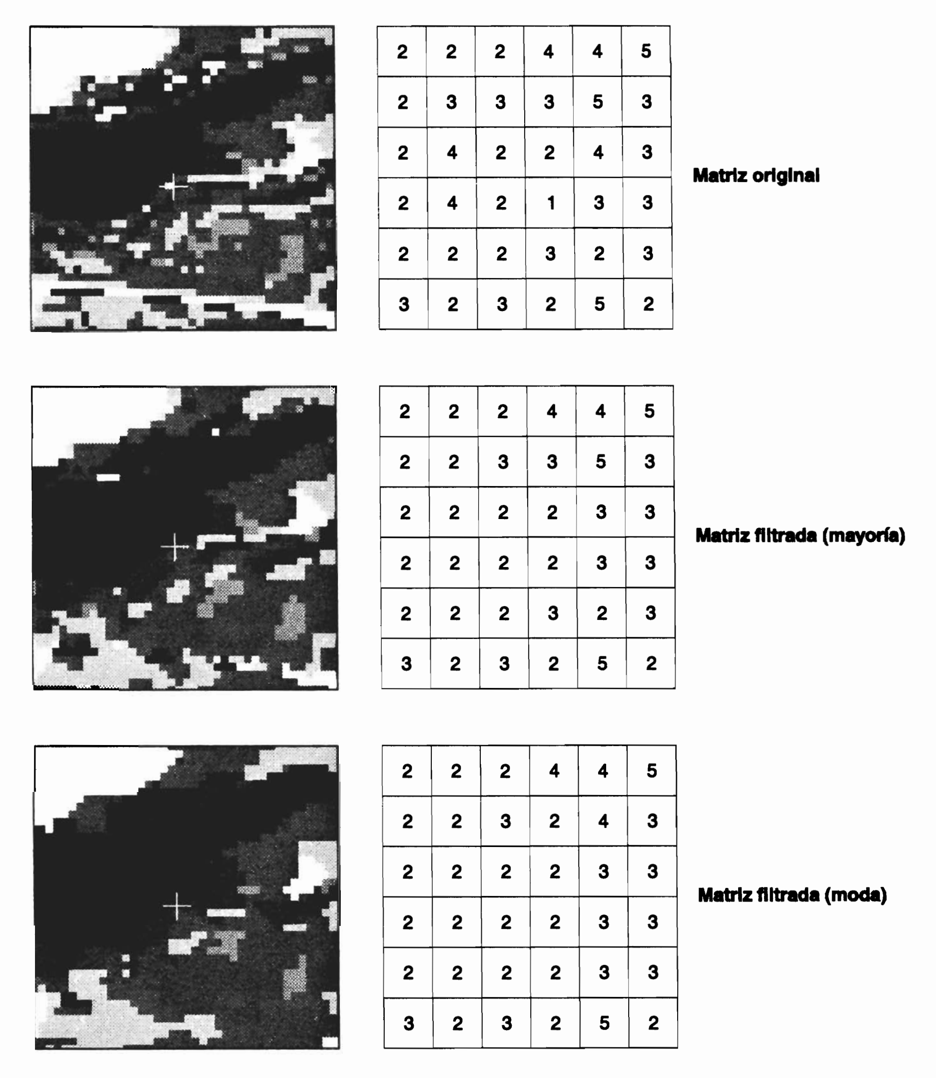
El tercer enfoque para emplear el contexto en la clasificación se centra en refinar los resultados, retocando algunas asignaciones en función de la clasificación de los píxeles vecinos. Cuando se emplean clasificadores píxel a píxel, es frecuente que los resultados aparezcan bastante fragmentados. Manchas de una cierta categoría se encuentran salpicadas por píxeles asignados a otras, perdiéndose su unidad geográfica y dificultando la interpretación y posterior representación cartográfica de los resultados. Este fenómeno se denomina coloquialmente en la bibliografía anglosajona efecto de «sal y pimienta» *(salt and pepper)* y se debe tanto al clasificador empleado como a la propia complejidad del paisaje, que explica la aparición de píxeles mixtos —fronterizos a dos o más categorías— de difícil asignación.

Para solventar este problema suele aplicarse una técnica de suavización de resultados, similar en la concepción, aunque no en la ejecución, a los filtros de paso bajo. Como ya hemos visto, sobre la imagen clasificada no puede aplicarse un filtro aritmético, ya que sus ND no guardan una relación cuantitativa entre sí, sino que sólo son etiquetas que definen las distintas categorías. Cualquier promedio de píxeles vecinos introduciría cambios imprevisibles en la clasificación, ya que no se trata de una imagen de tono continuo, sino de una imagen categorizada, en donde no tiene sentido establecer análisis de gradientes. Por esta razón, se aplican sobre la imagen otros esquemas de filtraje, basados sobre medidas categóricas en lugar de sobre promedios (Thomas, 1980). El objetivo último es reasignar aquellos píxeles aislados o poco significativos, facilitando una distribución espacial más nítida de las distintas categorías. Para ello, se procede a comparar la clase asignada a cada píxel con la que ofrecen los vecinos, modificándose en función de uno de los siguientes criterios (fig. 7.51):

1. *Moda.* El píxel situado en el centro de la matriz se asigna a la categoría más frecuente entre los píxeles de la ventana considerada, siempre que, lógicamente, no pertenezca ya a ella.
2. *Mayoría.* El píxel central se asigna a la categoría que cuente con la mitad más uno de los píxeles de la ventana. En caso de que ninguna categoría rebase ese valor, el píxel central mantiene su asignación primitiva.

La elección entre uno u otro método depende del tipo de paisaje analizado y del algoritmo que se haya empleado en la clasificación. Lógicamente, el primero ofrece una mayor generalización que el segundo, por lo que puede ser conveniente su empleo en caso de paisajes muy complejos y cuando la escala de trabajo sea regional o global. Se ha comprobado por diversos autores, que la aplicación de esta técnica proporciona un aumento significativo de la exactitud conseguida en la clasificación (Booth y Oldfield, 1989). Este efecto es debido, principalmente, a la eliminación de asignaciones anómalas debidas a píxeles de borde.

Uno de los problemas que presenta este método, sin embargo, es la difícil decisión sobre el tamaño de la ventana y el criterio de filtrado, ya que pueden provocar el efecto deseado en unas zonas de la imagen, pero ser excesivo o insuficiente en otras. Para solventar este problema se ha propuesto realizar la reasignación a partir de unos umbrales de tamaño variable, que filtren o no cada categoría a partir de un umbral de superficie crítico fijado para cada clase. Por debajo de ese valor, se



Matriz original

2	2	2	4	4	5
2	3	3	3	5	3
2	4	2	2	4	3
2	4	2	1	3	3
2	2	2	3	2	3
3	2	3	2	5	2

Matriz filtrada (mayoría)

2	2	2	4	4	5
2	2	3	3	5	3
2	2	2	2	3	3
2	2	2	2	3	3
2	2	2	3	2	3
3	2	3	2	5	2

Matriz filtrada (moda)

2	2	2	4	4	5
2	2	3	2	4	3
2	2	2	2	3	3
2	2	2	2	3	3
2	2	2	2	3	3
3	2	3	2	5	2

FIG. 7.51. *Reducción del ruido de la escena mediante filtros categóricos.*

considera que la fragmentación de la imagen implica ruido en la clasificación y el polígono es asignado a otra categoría (Barr y Barnsley, 2000). En el ejemplo propuesto por estos autores este esquema funcionó mucho mejor que los filtrados de mayoría convencionales para un ejemplo de cartografía urbana realizado a partir de imágenes aéreas de alta resolución.

Otros criterios de reclasificación pueden basarse en las propiedades espaciales de los píxeles, como su distancia, conectividad o inclusión. Un sencillo ejemplo del interés de estas relaciones es la discriminación entre cultivos herbáceos de regadío y parques urbanos. Ambas cubiertas presentan un comportamiento espectral similar, ya que de hecho ambas se riegan en verano y están compuestas por vegetación herbácea. Por tanto, para separarlas es preciso acudir al contexto espacial: un parque

estará emplazado en el interior de un área urbana, por lo que puede considerarse como tal si los píxeles situados a un cierto radio han sido asignados a la categoría urbana, asignándose a cultivos de regadío en caso contrario.

Pueden proponerse otros análisis basados en el contexto para realzar la clasificación temática. Por ejemplo, aplicando ciertos indicadores de idoneidad en función de la categoría contigua a cada píxel. Habitualmente, estos análisis se basan en matrices de aptitud, que ponderan el interés de que una categoría se presente junto a otra para un determinado objetivo. Un campo interesante de aplicación es la cartografía de hábitats idóneos para ciertos animales (Congalton *et al.*, 1993). La mezcla entre ciertas cubiertas vegetales complementa su dieta, haciendo esos lugares más atractivos para establecerse.

2.3.6. *Redes Neuronales Artificiales (RNA)*

Las RNA se utilizan para predecir un cierto comportamiento complejo, habitualmente a partir de una muestra de entradas y salidas observadas. Con los datos de esa muestra, la red «aprende» a reconocer el resultado a partir de los valores de entrada, clasificando el resto de las observaciones de acuerdo a esas reglas. Intentan, no siempre con mucho éxito, simular el comportamiento del cerebro humano (de ahí su nombre), mediante la interconexión múltiple entre unidades de activación (llamadas neuronas).

Aunque la descripción completa de esta técnica rebasa el enfoque de este libro, parece conveniente dedicarle unos párrafos en el contexto de la clasificación de imágenes, si bien también se emplean en teledetección con otros fines (Fang y Liang, 2003; Vega-Garcia y Chuvieco, 2006).

Una RNA está formada por un conjunto de elementos simples (neuronas, unidades de proceso), distribuidas en capas (fig. 7.52). Las unidades que forman una capa están conectadas con la capa o capas inmediatas a través de unas funciones de activación. Esas funciones se definen a partir de una serie de pesos ($w_{i,j}$), que se calculan de modo iterativo en el proceso de aprendizaje de la red. El objetivo de este aprendizaje es estimar unos resultados conocidos a partir de unos datos de entrada (muestra de control), para posteriormente calcular resultados desconocidos a partir del resto de datos de entrada. El aprendizaje se realiza a partir de todas las unidades que forman la red, variando el conjunto de los pesos en iteraciones sucesivas. Cada unidad de la red proporciona un valor de salida a partir de los valores de entrada, del modo siguiente (Richards, 1993):

$$o = f(w\,x + \theta) \qquad \{7.42\}$$

donde *o* indica el resultado, θ es un umbral (en muchas ocasiones se deja a cero), *w* un vector con los pesos que unen las distintas unidades de la red, y *x* el vector de entradas. Ese valor de salida puede ser a su vez la entrada de unidades situadas en la capa siguiente o en la anterior, dependiendo del tipo de red.

El número de unidades y de capas depende de las condiciones del problema en estudio, siendo más complicado el proceso de aprendizaje cuanto mayor dimensión tiene la red. En clasificación de imágenes es frecuente que las RNA estén formadas

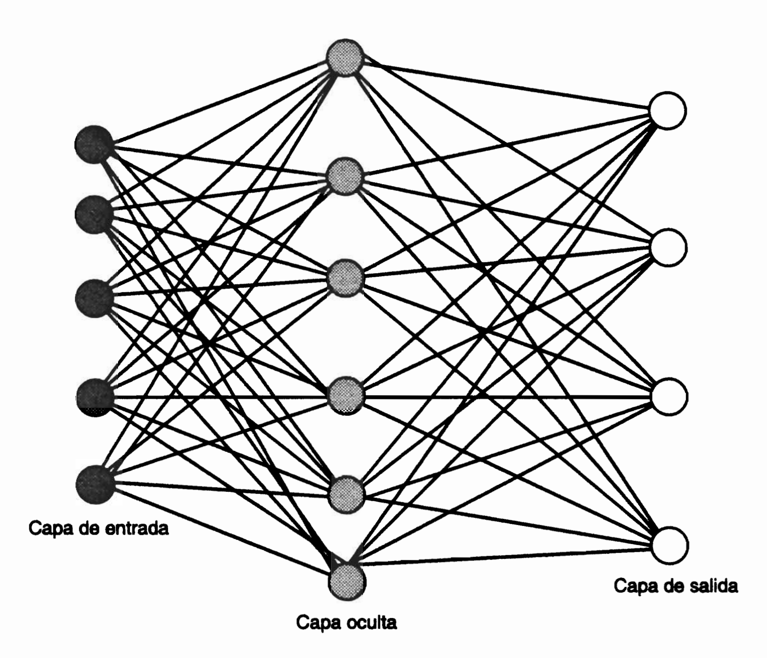


FIG. 7.52. *Esquema de una red neuronal.*

por tres capas, denominadas de entrada, oculta y de salida. El objetivo de la capa oculta es lograr funciones de discriminación más flexibles. El número de las unidades de entrada está en relación con los valores que sirvan para entrenar a la red, habitualmente una por cada banda empleada en la clasificación, si bien es necesario utilizar una cadena de unidades por banda para poder codificar el rango completo de ND (0 a 255) (Benediktsson *et al.*, 1990). El número de unidades de salida coincide con el de clases que pretendan clasificarse, mientras el número en la capa oculta puede variar, aunque se recomienda sea al menos igual al de la capa de entrada (Richards, 1993).

El punto más álgido de las RNA es el denominado «aprendizaje» de la red, esto es la adecuada configuración de las conexiones y pesos entre las unidades de la red para lograr un resultado óptimo. Entre los diversos criterios de aprendizaje, el más conocido es el denominado de retro-propagación. Tiene por objetivo encontrar un conjunto de pesos que asegure que cada vector de entrada producido por la red sea el mismo, o muy similar, al de salida conocido. Su formulación puede sintetizarse de la siguiente forma (para un análisis más detallado, véase [Rumelhart, 1986, #1123} y Richards, 1993, pp. 207-224):

1. Asignar unos pesos arbitrarios a la red para obtener unos resultados a partir de los valores de entrada (en nuestro caso, los ND de las áreas de entrenamiento en las distintas bandas). Esos resultados se contrastan con la categoría a la que pertenece cada píxel de entrenamiento (introducida por el usuario). Esto permite obtener una tasa de error inicial. La medida habitual del error es la desviación cuadrática entre el resultado esperado (t_k) y el producido por la red (o_k):

$$E = \sqrt{\sum_{k=1,n} \sum_{m=1,c} (t_{k,m} - o_{k,m})^2} \qquad \{7.43\}$$

para todo resultado esperado m (en nuestro caso para las c categorías) en todas las unidades de entrada k (en nuestro caso las bandas, n, a introducir en la clasificación).

2. A partir de ahí, se van modificando iterativamente los pesos en las distintas capas, desde la de salida hasta la de entrada, con el objetivo de reducir el error global (se propaga el error hacia atrás, de ahí el nombre del ajuste), hasta que éste sea muy pequeño o nulo (en ese caso todas las muestras introducidas en el aprendizaje estarían bien clasificadas), o bien se hayan cumplido el número de iteraciones indicadas por el intérprete. El número de iteraciones para lograr el objetivo marcado por el usuario (el nivel de convergencia de la red) puede ser muy elevado, dependiendo de la complejidad del problema (en clasificación de la cubierta del suelo, se han propuesto hasta 250.000 iteraciones: [Civco, 1993, #2533]).

Para ilustrar el proceso de aprendizaje, puede ser de interés estudiar un sencillo ejemplo de clasificación propuesto por Richards (1993, pp. 219-223). En ese caso se trata de un conjunto de seis elementos que forman dos categorías (c_1 y c_2) que tratan de discriminarse por funciones lineales (fig. 7.53). Los valores de estos seis elementos son:

$$c_1 = (-4,3)\ (-4,-3)\ (-1,0)$$

$$c_2 = (-2,-3)\ (-2,3)\ (1,0)$$

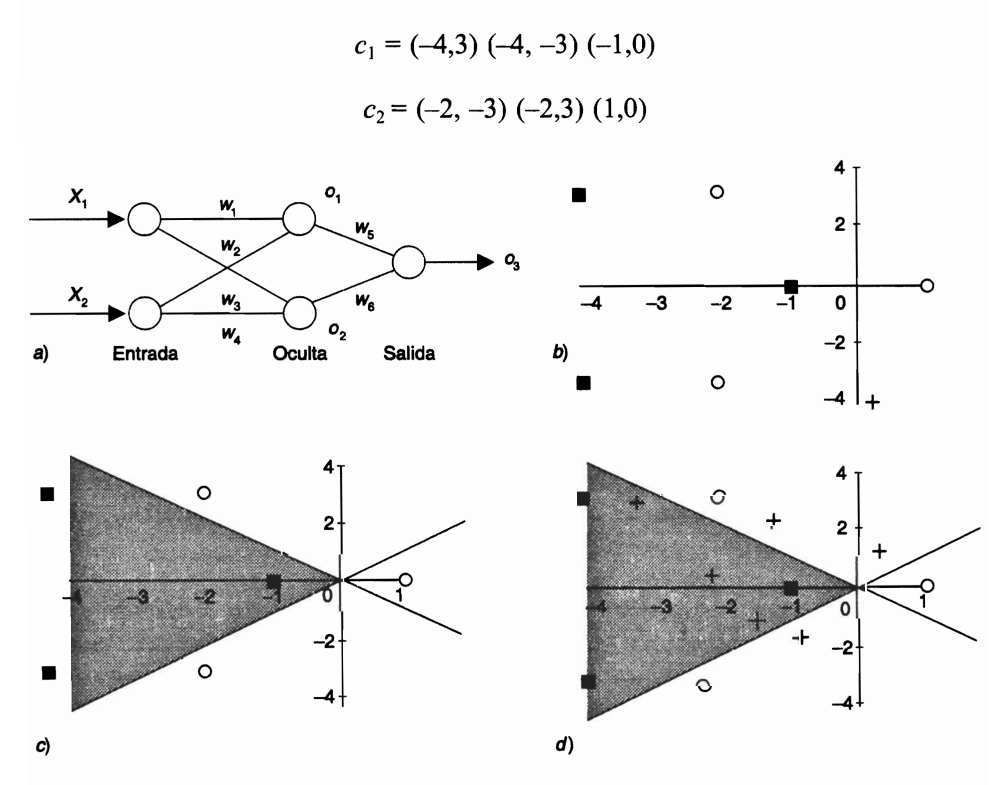


FIG. 7.53. *Ejemplo de aplicación de una red neuronal (Richards, 1993).*

TABLA 7.10. *Valores de los coeficientes de ponderación y del error en la red del ejemplo para distinto número de iteraciones (Richard, 1993)*

Iteración	w_1	w_2	w_3	w_4	w_5	w_6	*Error*
0	0,050	0,100	0,300	0,150	1,000	0,500	0,461
1	0,375	0,051	0,418	0,121	0,951	0,520	0,424
5	0,606	0,007	0,570	0,117	1,240	0,909	0,391
10	0,642	–0,072	0,641	0,196	1,464	1,034	0,378
50	2,224	–2,215	2,213	2,216	3,302	3,259	0,040
150	2,810	–2,834	2,810	2,835	4,529	4,527	0,007
250	2,901	–2,976	2,902	2,977	4,785	4,784	0,005

Claramente se observa en la fig. 7.53*b* que estas dos clases no son separables por ecuaciones lineales sin cometer algún error en la asignación. Para clasificarlas, se establece una RNA con tres capas: dos unidades de entrada, dos ocultas y una de salida, lo que implica seis conexiones y, por tanto, calcular seis pesos y el valor del error (θ). Siguiendo los criterios antes indicados se inicia el entrenamiento de la red con unos pesos arbitrarios, que dan lugar a un margen relativamente grande de error (0,461: tabla 7.10). Como puede observarse los pesos se modifican en cada iteración (aquí se ha resumido la tabla de resultados), así como el error residual, que va disminuyendo hasta un valor que consideramos adecuado. En ese momento, los pesos sirven para calcular las conexiones entre las unidades de la red:

De la capa de entrada a la capa oculta:

$$o_1 = 2{,}901\ x_1 - 2{,}976\ x_2$$

$$o_2 = 2{,}902\ x_1 + 2{,}977\ x_2$$

y de la capa oculta a la de resultados:

$$o_3 = 4{,}785\ o_1 + 4{,}784\ o_2$$

La asignación de una unidad de la muestra a una de las dos clases se hace en función de los resultados que ofrezca o_3. Como se trata sólo de dos categorías, la entrada se asigna a la clase 1 si el resultado o_3 está más cerca de 0, y a la 2 si está más cerca de 1.

Si igualamos a cero las dos primeras ecuaciones, resultan entre ambas un marco idóneo para separar las dos categorías de nuestro ejemplo (fig. 7.53*c*). Ahora bien, esas rectas pueden considerarse como un paso intermedio (están en la capa oculta) para obtener la ecuación final, en la cual se discriminan las dos categorías perfectamente con una función lineal. Simplificando las cosas, esas ecuaciones intermedias pueden concebirse como un medio de transformar el espacio de medida original para lograr una separación idónea entre los miembros de cada clase. Habitualmente no se utilizan ecuaciones lineales para obtener los valores de salida de una neurona, sino funciones más complejas, como sigmoides (el valor de salida está comprendido entre 0 y 1), o hiperbólica-tangente (valor de salida de –1 a +1) (Civco, 1993).

Una vez realizado el aprendizaje, pueden introducirse nuevos casos de asignación desconocida, para que la RNA los clasifique en función de las ponderaciones previamente calibradas. En este ejemplo, se añaden algunos casos en las proximidades de los inicialmente planteados; en todos ellos la asignación es correcta (fig. 7.53*d*). El proceso de clasificación se realiza simplemente asignando valores a las variables de entrada x_1 y x_2. Como ya hemos indicado, el valor de salida o_3 se redondea al entero más cercano para asignar el caso a la primera o segunda categoría.

En el contexto de la clasificación de imágenes se ha comprobado la potencialidad de las RNA como alternativa a los clasificadores estadísticos tradicionales, especialmente cuando no pueden asumirse distribuciones normales de las categorías, ya que las RNA son independientes del tipo de distribución. En varias ocasiones se ha contrastado su utilidad frente a estos clasificadores, lográndose resultados comparables o aún mejores. En general, la discriminación de las muestras de entrenamiento resulta más adecuada que con los clasificadores convencionales (Benediktsson *et al.*, 1990; Foody, 1995), pero la asignación propiamente de la imagen muestra una gran dependencia de la calidad del entrenamiento. Las RNA pueden incluir bandas auxiliares no espectrales, que pueden ser incluso nominales, como mapas de suelos o de propiedad de la tierra. En algunos trabajos se ha comprobado la gran robustez de esta técnica (poco sensible a valores extremos) y su habilidad para incluir elementos texturales, ofreciendo así una clasificación con menos ruido que la basada en los métodos píxel a píxel convencionales (Bischof *et al.*, 1992; Civco, 1993; Hepner *et al.*, 1990). También se ha sugerido su aplicación a la estimación de parámetros físicos, como el índice de área foliar y el contenido de clorofila (Fang y Liang, 2003; Fourty y Baret, 1997), así como técnica alternativa de ajuste para modelos de evaluación de riesgo (Carvacho, 1998; Vega-García *et al.*, 1996).

Entre los problemas de las RNA cabe citar la falta de criterios generales para diseñar la estructura de la red (número de capas, unidades en cada capa), reduciéndose su empleo a una cuestión de prueba y error; su lento y tedioso entrenamiento (que desaconseja su empleo cuando el número de clases o de bandas es muy grande: (Clark y Cañas, 1995); la posibilidad de que se encuentre mínimos locales y de que se produzca un sobre-entrenamiento de la red. Esto ocurre cuando se ajustan muy bien los datos de entrada, pero la red es poco generalizable a otros datos. Para evitar esto, suele dividirse la muestra de aprendizaje en dos grupos, uno para calcular los pesos y otro para verificar el ajuste. También pueden plantearse las redes para la clasificación no supervisada, ya que existen algunos criterios de aprendizaje que no requieren una previa definición de las clases deseadas.

Para la clasificación por RNA de la imagen Torre100 empleamos tres fases. En la primera, se define la estructura de la red: número de unidades de entrada (6 en nuestro caso, una por banda), número de capas ocultas (1 en nuestro caso), número de clases de entrenamiento y valor temático de cada clase. En nuestro caso, se trata de las 7 categorías de cobertura previamente descritas. El siguiente programa se dedica a entrenar a la red a reconocer las categorías que quieren discriminarse. Existen algunos parámetros de control que modifican el proceso de aprendizaje, como el índice de momento, el índice de aprendizaje, el error máximo normalizado, el individual y el número máximo de iteraciones. Para nuestro caso, se aceptaron los valores recomendados por el programa: 0,9 para el momento; 0,1 para el aprendizaje;

0,01 para el máximo error; 0,001 para el máximo error individual, y 1.000 iteraciones. Después de completar el número de iteraciones, el error máximo se situó en 0,0354. Aunque no garantizaba el indicado previamente, nos pareció suficiente para este ejemplo didáctico. Tras entrenar a la red, el paso siguiente es asignar los píxeles de la imagen a cada categoría temática, conociendo los pesos obtenidos previamente. La clasificación por RNA fue más rápida que la realizada con el algoritmo de máxima probabilidad, descontando lógicamente el lento proceso de aprendizaje. Comparándola con las clasificaciones antes comentadas, se observó una mejor discriminación del pinar, que aparece mejor representado en las zonas serranas del NW de la imagen, mientras el suelo descubierto, principalmente roquedo en esos sectores, se asignó en algunos sectores al matorral. En el resto de la imagen, el suelo descubierto se clasificó bien, así como los pastizales y cultivos de secano, excesivamente representados en la clasificación de máxima probabilidad. La combinación matorral-encinar siguió sobre-dimensionada, especialmente en el centro y norte de la imagen.

2.3.7. *Clasificación borrosa* (fuzzy classification)

Previamente hemos señalado el interés de las técnicas que permiten obtener información sobre la mezcla en el interior de un píxel. Considerar un píxel como un compuesto de varios elementos resulta cada vez más común, si se considera el espacio como un continuo, sin barreras muy precisas, al menos en lo que se refiere a la mayor parte de las variables ambientales (Tso y Mather, 2001).

En el campo de la clasificación este enfoque lleva consigo modificar los planteamientos convencionales, en donde cada píxel se asigna a una sola categoría. De ahí que se denomine a estos clasificadores como «rígidos» *(hard classifiers)*. Estos clasificadores pueden conducirnos a errores notables, cuando existan píxeles mixtos. Por ejemplo, en el criterio de máxima probabilidad, un píxel se asigna a la clase más probable independientemente de que la probabilidad de pertenencia a esa categoría sea muy superior a pertenecer al resto (digamos que 0,9 sobre 0,1) o que sólo la supere por un estrecho margen (0,55 frente a 0,45). En el primer caso, el error de clasificar ese píxel es bastante bajo, mientras en el segundo la asignación es muy arriesgada.

Las técnicas de clasificación borrosa *(fuzzy)* permiten aliviar este problema. En pocas palabras, se considera una pertenencia borrosa a una categoría cuando se admite un grado de pertenencia. En este enfoque, cada píxel se etiqueta en varias categorías, con un valor más o menos alto en función de su similitud espectral (fig. 7.54). Convencionalmente, la función de pertenencia corresponde a una distribución binaria (0 no pertenece, 1 pertenece), pero puede concebirse un función de pertenencia comprendida entre 0 y 1, lo que permitiría una asignación simultánea a varias categorías, con diferentes grados de pertenencia (Wang, 1990):

$$U_{i,j} = f(\mathrm{ND}_x) \qquad \{7.44\}$$

donde $U_{i,j}$ indicaría el grado de pertenencia del píxel x a la clase i, y puede ser un número real comprendido entre 0 y 1.

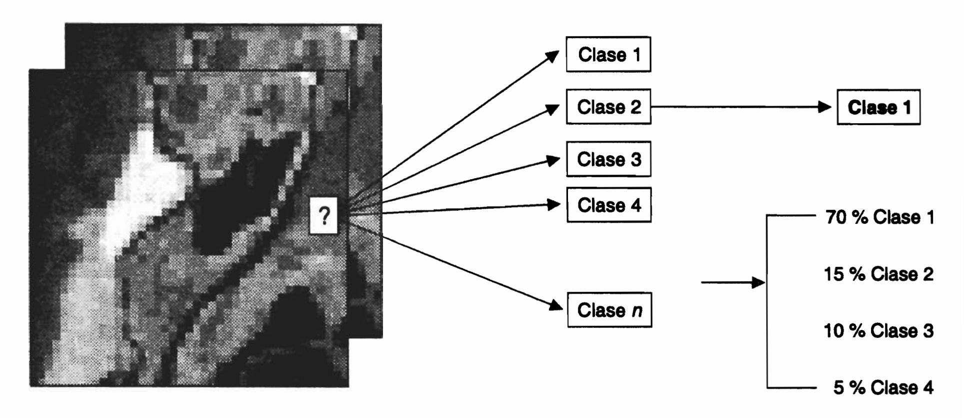


FIG. 7.54. *La clasificación borrosa permite asignaciones múltiples en el mismo píxel.*

En aplicaciones de teledetección, los métodos más habituales para obtener esos valores de pertenencia son la variante borrosa de máxima probabilidad (Maselli *et al.*, 1995; Wang, 1990) y un tipo especial de análisis no supervisado, denominado c-medias borrosas (Fisher y Pathirana, 1990; Foody, 1992). Por simplificar la exposición, nos vamos a centrar en el primer criterio, ya que es muy similar al de máxima probabilidad antes analizado. En el trabajo de Fisher y Pathirana (1990) se incluye la formulación completa del criterio c-medias borrosas.

En un enfoque de lógica borrosa, para calcular el grado de pertenencia de un píxel a las distintas categorías de la leyenda, asumiendo una distribución de probabilidad normal en las categorías, podemos emplear las siguientes definiciones del vector de medias y la matriz de varianza-covarianza (Wang, 1990):

$$M_A^* = \frac{\sum_{i=1,n} U_A(M_i) M_i}{\sum_{i=1,n} U_A(M_i)} \qquad \{7.45\}$$

y

$$V_A^* = \frac{\sum_{i=1,n} U_A(M_i)(M_i - M_A^*)(M_i - M_A^*)^T}{\sum_{i=1,n} U_A(M_i)} \qquad \{7.46\}$$

donde U_A indica el grado de pertenencia a la clase A, M el vector de ND formado por los n píxeles utilizados en la muestra, y V_A la matriz de varianza-covarianza para esa clase. El asterisco en el vector M_A y la matriz V_A indica que se trata de medias y varianza-covarianza para un espacio borroso *(fuzzy)*.

A partir de esos dos valores, puede calcularse la probabilidad de pertenencia a ese espacio, variando ligeramente las fórmulas de la probabilidad bayesiana:

$$p^*(x / A) = (2\pi)^{-m/2} \left|V_A^*\right|^{-0,5} \exp\left\{-0,5(M_x - M_A^*)^T V_A^{*-1}(M_x - M_A^*)\right\} \qquad \{7.47\}$$

El resultado de este cálculo permite conocer la probabilidad de incluirse en cada categoría *A*. Esa probabilidad se considera el grado de pertenencia de ese píxel a dicha categoría. Por tanto, se obtienen tantas imágenes clasificadas como categorías se consideren. El ND de cada una de esas imágenes indica el grado de pertenencia a las distintas categorías.

Las áreas para estimar las estadísticas de entrenamiento pueden ser homogéneas —como en la clasificación convencional— o, ahí la novedad, heterogéneas, con componentes mixtos, siempre que se conozca su grado de mezcla. Las aplicaciones de esta lógica borrosa son de especial interés cuando se pretenda analizar coberturas con alto grado de mezcla, como es el caso de las categorías urbanas o cuando se aborden inventarios de vegetación. En varios trabajos se ha obtenido una buena correlación entre el grado de cobertura de distintas clases, observado en fotografía aérea de alta resolución, y los grados de pertenencia ofrecidos por la clasificación borrosa, tanto para clases urbanas (Fisher y Pathirana, 1990), como para densidades de vegetación (Foody, 1992). Un interesante campo de aplicación es el inventario forestal, donde este tipo de clasificación puede facilitar datos de gran interés para la estimación global de densidades y superficies. En un trabajo piloto realizado en Italia, los ajustes entre las observaciones de terreno y los componentes *fuzzy* son mucho más altos que para las bandas originales (reducidas mediante componentes principales), especialmente en la estimación del área basal (Maselli *et al.*, 1995).

Aunque en el origen esta técnica procede de una concepción bastante distinta al análisis lineal de mezclas espectrales (ALME) previamente analizado, los resultados que ofrecen tienen bastante en común. Ambas técnicas pretenden derivar información subpíxel, expresando el grado de pertenencia *(fuzzy)* o la proporción (ALME) de una determinada categoría. Son pocos los trabajos que han comparado las ventajas e inconvenientes de ambas técnicas, en cuanto a eficacia para resolver las mezclas, tiempo de cálculo y limitaciones. Cuando se han abordado simultáneamente, los resultados parecen ofrecer una gran coincidencia entre los dos métodos (Foody y Cox, 1994). Este concepto de asignación borrosa puede extenderse a la integración de variables de distintas fuentes o a la comparación multitemporal, permitiendo la posibilidad de señalar distintas intensidades de cambio (Foody, 2001).

La figura 7.55 muestra un ejemplo de clasificación borrosa. Recoge una asignación múltiple realizada a partir de una clasificación de máxima verosimilitud de la imagen Barrax99. En este caso, se grabaron los cálculos de probabilidad para cada píxel, de tal manera que pueden reconstruirse sus asignaciones potenciales al resto de categorías de interés. Por ejemplo, se distinguen los píxeles que se asignaron a la categoría alfalfa en función de a qué categoría lo hicieron en segunda y tercera opción (legumbres, trigo y suelo son las alternativas). De esta forma, podemos distinguir entre los píxeles que aun clasificándose como alfalfa tienen una mayor tendencia a ser trigo, legumbres o suelo, en distinto orden, y por tanto qué tipo de estado vital tenían en el momento de adquirirse los datos. Por ejemplo, si un píxel es categorizado como alfalfa y suelo, se tratará de una zona con menor cobertura vegetal que otra clasificada como alfalfa y trigo.

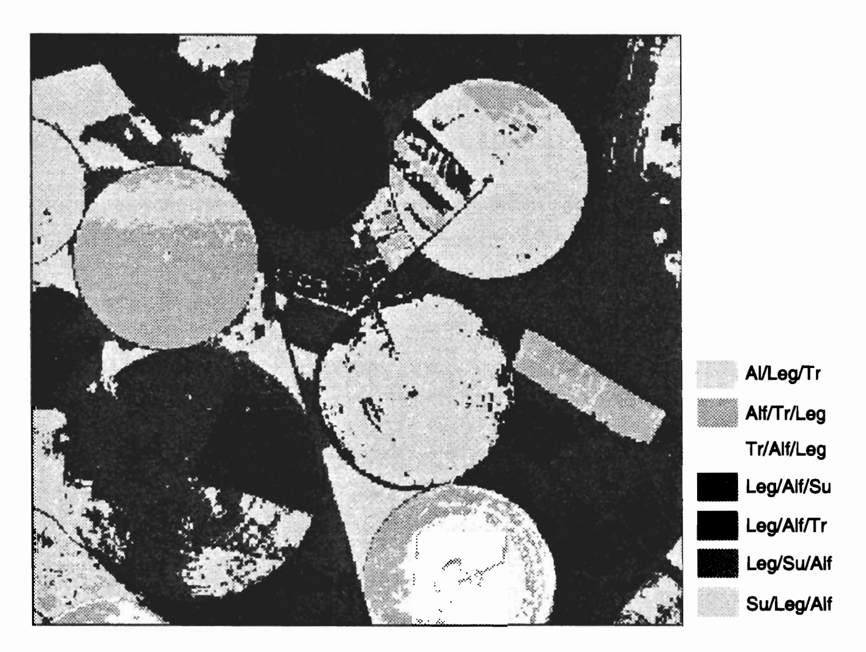


FIG. 7.55. *Clasificación borrosa de la imagen Barrax99 (Alf: alfalfa; Leg: legumbres; Tr: trigo; Su: suelo).*

2.4. Obtención y presentación de resultados

Independientemente del método empleado en la clasificación digital, los resultados se almacenan en una nueva imagen, similar a las originales, en cuanto a estructura y tamaño, pero con la importante diferencia de que el ND de cada píxel no corresponde a un valor de reflectividad, sino a la categoría a la que se asignó. En definitiva, obtenemos una nueva matriz numérica, similar a la original aunque de dos dimensiones, pues se ha condensado la información espectral (varias bandas) en una sola clase temática. Esa nueva imagen puede ser el producto final del trabajo, o servir como estadio intermedio de un proyecto más amplio, en donde la teledetección se combine con otro tipo de variables espaciales.

Esa nueva imagen puede dar lugar a dos tipos de productos: cartográficos y estadísticos. En el primer caso, se trata de convertir la imagen clasificada en un mapa; en el segundo, de realizar un inventario a partir de los ND que componen esa imagen.

2.4.1. *Productos cartográficos*

La imagen clasificada puede convertirse en un mapa temático, similar a los convencionales, empleando algunas técnicas ya comentadas en anteriores capítulos. En primer lugar, conviene simplificar los resultados de la clasificación aplicando algún filtro modal, de tal forma que se generalicen los polígonos que fonnan la clasificación. Esto facilita también su conexión con un SIG como luego veremos.

Seguidamente, se requiere dotar a esa imagen de una validez cartográfica, de tal forma que se ajuste a un sistema de coordenadas determinado. Por cuanto el resultado de la clasificación es también una imagen digital, pueden aplicarse sobre ella los métodos de corrección geométrica antes comentados (6.6.3). Basta identificar puntos comunes entre la imagen y el mapa de referencia, aplicar algún polinomio de transformación, y proceder al trasvase de los ND a su nueva posición. Conviene recordar que, en este caso, ese trasvase debe realizarse con el criterio del vecino más próximo, puesto que cualquier otro —que implique promediar las categorías— invalidará los resultados de la clasificación. Obvia decir que los puntos de control pueden localizarse sobre las bandas originales, ya que tienen la misma geometría de las clasificadas, y aplicar luego sobre éstas el modelo de corrección. Localizar puntos sobre una imagen clasificada sería muy problemático, ya que se pierden la mayor parte de los rasgos lineales de la imagen original.

Una vez posicionada correctamente, la imagen clasificada requiere contar con una serie de elementos gráficos, que faciliten su lectura. Uno importante es generar una tabla de color apropiada al significado temático de cada una de las categorías. En este sentido, conviene respetar las convenciones establecidas en la asignación temática de colores: por ejemplo, rojo para las zonas urbanas, verde para las forestales, ocre para las agrícolas, etc. (Anderson *et al.*, 1976; Coleman, 1968), en lugar de atribuir colores arbitrarios a las categorías.

Como ya se comentó, la manipulación numérica del color ofrece al intérprete una amplia paleta de colores: de 0 a 255 niveles, por cada uno de los tres cañones de color. De esta forma, para diseñar un color apropiado a cada categoría, basta indicar tres valores numéricos, entre 0 y 255, que expresen el nivel de RVA asignado a dicha clase. En clasificaciones temáticas, quince o veinte colores, bien discriminables entre sí, serán suficientes para visualizar el resultado. Un mayor número de categorías complicaría notablemente la interpretación y, en consecuencia, la legibilidad del documento final.

Basta añadir al mapa un conjunto gráfico apropiado para que se culmine el proceso de edición. Elementos de interés, en este sentido son: una leyenda de color, que identifique las categorías presentes en el mapa y el color que se les asigna; una escala gráfica, para identificar adecuadamente la proporción del área representada, y una serie de rótulos identificativos de la zona y/o del proceso realizado. Caso de que se disponga de información vectorial complementaria, como carreteras o ríos, puede ser conveniente superponerlos a la imagen como líneas de referencia. La figura 7.56 recoge un ejemplo de algunos elementos cartográficos que pueden asociarse a una imagen clasificada.

Una vez que el resultado es satisfactorio, el último paso se dirige hacia la reproducción de la imagen clasificada en un soporte permanente, ya sea papel o película, utilizando cualquiera de los periféricos disponibles. Para productos cartográficos de amplia cobertura, la impresión puede realizarse en línea, si uno dispone de un periférico de gran formato, o bien salvar la composición cartográfica como archivo e imprimirlo posteriormente en un centro que disponga de ese equipo. Actualmente hay formatos gráficos bastante estándar (.TIF, .EPS) que permiten acceder fácilmente a periféricos de gran calidad que no tienen porqué estar relacionados con aplicaciones específicas de teledetección. Muchas empresas de artes gráficas, por

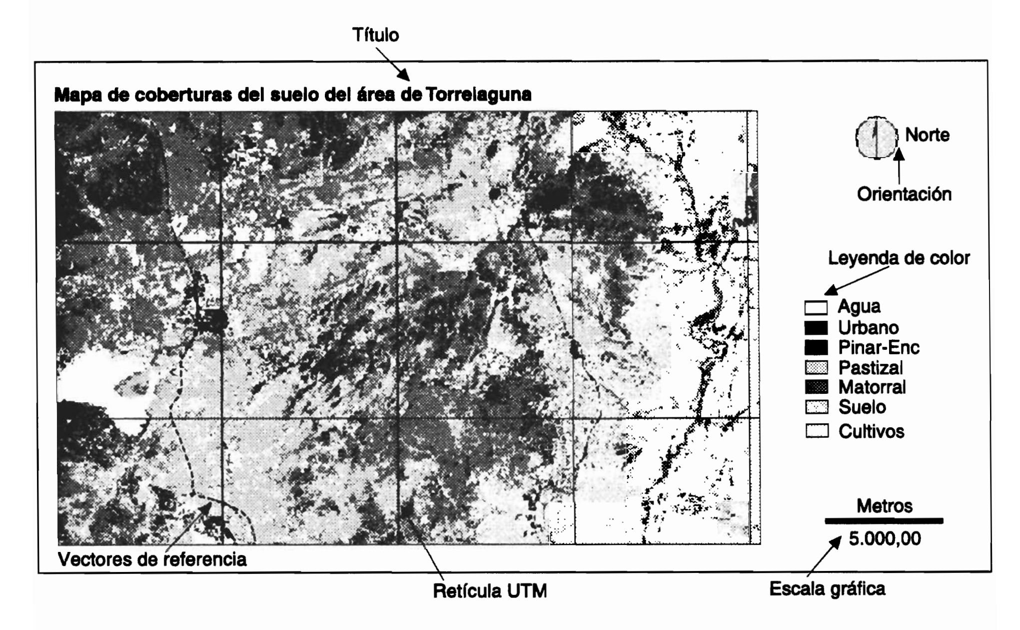


FIG. 7.56. *Elementos cartográficos incorporados a la clasificación de la imagen Torre100.*

ejemplo, disponen de estos equipos (*plotters* de inyección de tinta de diverso tamaño y resolución). En consecuencia, puede ser más conveniente acudir a ellos cuando, esporádicamente, sea precisa una salida gráfica de mayor tamaño, en lugar de realizar la fuerte inversión que implican. Lógicamente, eso dependerá de la intensidad de uso que se vaya a realizar de estos aparatos.

2.4.2. *Productos estadísticos*

El inventario superficial de los resultados es una de las principales ventajas de la clasificación digital. Una simple tabulación de frecuencias permite obtener el inventario del área clasificada; esto es, el número de píxeles incluidos en cada una de las categorías. Puesto que es conocida la dimensión superficial de cada píxel, resulta inmediato obtener la extensión ocupada por cada categoría. Por el contrario, para alcanzar el mismo objetivo el análisis visual requiere planimetrar cada una de las zonas delimitadas por el intérprete, lo que resulta una labor lenta, fatigosa y, frecuentemente, inexacta.

El tratamiento digital permite calcular superficies sobre toda la imagen, o sobre polígonos determinados. Si esos polígonos coinciden con unidades administrativas (municipios, comarcas), puede obtenerse un inventario de gran interés para las estadísticas oficiales. Por ejemplo, una clasificación agronómica de la imagen puede facilitar estadísticas de cultivo a veces inaccesibles por medios convencionales. Varios trabajos han ensayado el uso alternativo de esta metodología frente a las fuentes de información tradicionales, como el catastro o las hojas de cultivos (GDTA-CEE, 1982).

A modo de ejemplo, la tabla 7.11 recoge el inventario de los tipos de ocupación de la imagen de nuestro ejemplo, tal y como aparecen clasificados mediante

TABLA 7.11. *Inventario de la ocupación del suelo en la imagen Torre100 de acuerdo a dos criterios de clasificación*

	Clasificación de máxima probabilidad			*Clasificación por RNA*		
	Píxeles	*Hectáreas*	*%*	*Píxeles*	*Hectáreas*	*%*
Urbano	110.553	6.909	13,27	67.365	4.210	8,08
Pastizal	178.735	11.170	21,45	226.811	14.175	27,22
Matorral	275.265	17.204	33,03	380.854	23.803	45,71
Pinar-encinar	9.839	614	1,18	16.766	1.048	2,01
Suelo	9.133	570	1,10	12.150	759	1,46
Cultivo	236.848	14.803	28,42	97.519	6.095	11,70
Agua	12.907	806	1,55	31.815	1.988	3,82
TOTAL	833.280	52.080	100,00	833.280	52.080	100,00

máxima probabilidad y RNA. Vemos las notables diferencias entre ellas, especialmente para las categorías más dominantes: matorral, pastizal y cultivos, que no son tan evidentes en el análisis visual de los resultados.

3. Técnicas de análisis multitemporal

3.1. EL FACTOR TIEMPO EN LOS ESTUDIOS DE TELEDETECCIÓN ESPACIAL

Una de las aportaciones más destacadas de la teledetección espacial al estudio del medio ambiente es su capacidad para seguir procesos dinámicos. Al tratarse de información adquirida por un sensor situado en una órbita estable y repetitiva, las imágenes de satélite constituyen una fuente valiosísima para estudiar los cambios que se producen en la superficie terrestre, ya sean debidos al ciclo estacional de las cubiertas, ya a catástrofes naturales o a alteraciones de origen humano.

En el seguimiento de la dinámica de un determinado fenómeno conviene distinguir dos aspectos relacionados con el cambio (Rodin, 1998): por un lado, la rapidez con que el fenómeno se produce, y por otro la pervivencia del cambio que implica (fig. 7.57). El primer aspecto hace referencia a la escala temporal en la que se manifiesta un fenómeno o, dicho de otra forma, a su duración en el tiempo. En este sentido, el rango de los fenómenos ambientales que se estudian en teledetección puede ir desde unas pocas horas (ciclones tropicales, terremotos, erupciones volcánicas) hasta varios años (desertificación, crecimiento urbano). El segundo aspecto se relaciona con la permanencia de los efectos de esa perturbación, que también puede variar en un ciclo de pocos días hasta varios años. El efecto de una inundación puede ser breve, si ésta fue superficial, o bastante permanente, si ha supuesto la modificación de algunos rasgos geomorfológicos (deslizamientos, por ejemplo). En definitiva, la pervivencia de los efectos y la duración del fenómeno no tienen por qué estar relacionados, o, dicho de otro modo, un fenómeno de corta duración puede tener una larga continuidad y viceversa.

La frecuencia más idónea para observar un determinado fenómeno dependerá

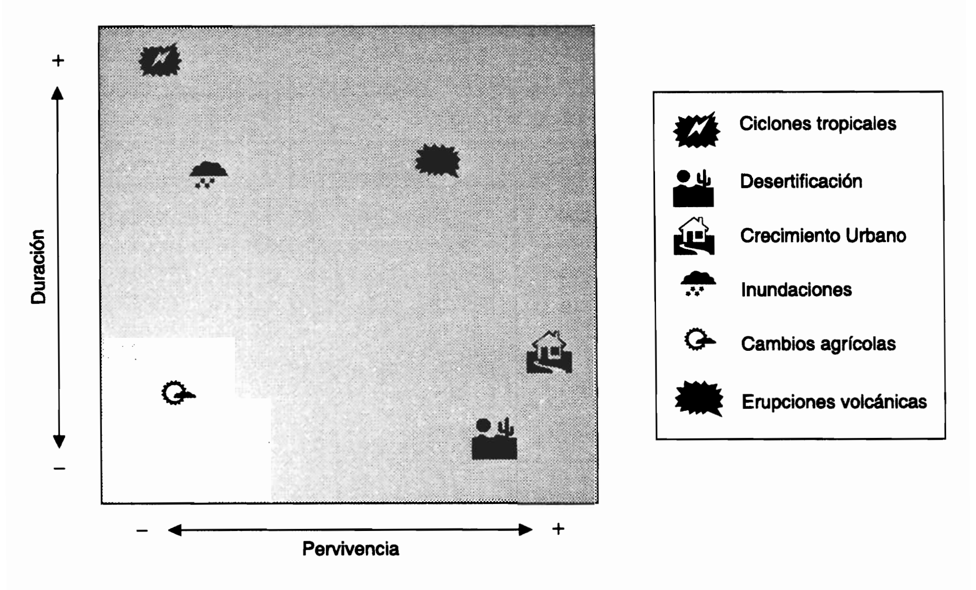


FIG. 7.57. *Escalas temporales de cambio para algunos fenómenos ambientales.*

de ambas variables: duración y pervivencia. Algunos procesos requieren una observación prácticamente continua, como puede ser la cartografía de nubes, mientras para otros bastará un inventario anual (cultivos) o quinquenal (cobertura del suelo). La tabla 7.12 presenta algunas cadencias de observación recomendables, según los fenómenos que se pretenda observar (Jensen *et. al.*, 1983).

Como ya hemos visto, la frecuencia de observación depende de las características orbitales y anchura del área observada por el sensor, si bien en términos prácticos ese período se alarga si consideramos la cobertura nubosa o carencias del sistema sensor (falta de antenas receptoras, fallos en la adquisición o transmisión). Los sistemas actuales de teledetección proporcionan una amplia variedad de cadencias de observación, desde pocos minutos para los satélites meteorológicos de órbita geo-estacionaria y amplia cobertura, hasta varias semanas para los de recursos naturales, con órbitas más bajas y cobertura territorial mucho más limitada. Si en los primeros años de la teledetección, la resolución espacial del sensor se consideraba el

TABLA 7.12. *Cadencia de actualización para estudios multitemporales*

Fenómeno	*Período de observación recomendable*
Dinámica atmosférica	15-30 minutos
Seguimiento de desastres	2-24 horas
Evaluación de desastres	1-7 días
Predicción de cosechas	2-3 meses
Análisis de la deforestación	1-3 años
Actualización de mapas de cobertura	3-5 años
Dinámica urbana	5-7 años
Actualización de mapas topográficos	10-20 años

elemento más crítico para valorar su potencialidad, la cobertura temporal cada vez se califica como un criterio más protagonista, al subrayarse la necesidad de contar con información suficientemente actualizada. Por ejemplo, para evaluar las condiciones vegetales a corto plazo, de cara a predecir el rendimiento de un cultivo o el peligro de incendios —por poner dos ejemplos de gran interés territorial—, de nada serviría una alta precisión espacial sin el adecuado ciclo de cobertura. Un fino detalle espacial no es suficiente para estimar operativamente el riesgo de incendio si sólo contamos con una imagen cada 16 días. Será preferible, en este contexto, emplear imágenes menos detalladas, siempre que proporcionen información más frecuente.

Para que puedan abordarse estudios multitemporales con teledetección es preciso que el sistema sensor proporcione una cobertura periódica, en las mismas bandas espectrales, y con condiciones de observación similares (altura, hora, ángulo de adquisición). Estos requisitos los cumplen la mayor parte de los satélites de recursos naturales, excepción hecha de los sensores instalados sobre el *Space Shuttle* que no ofrecen una cadencia y homogeneidad adecuada, si bien permiten comparaciones visuales-cualitativas de gran interés. Éste es también el caso de los sensores aerotransportados, singularmente de la fotografía aérea, que se ha utilizado profusamente para analizar la dinámica de la cobertura del suelo (Martínez Vega, 1989, #1268).

Como ya vimos en el capítulo 5, la dimensión temporal puede considerarse en teledetección con un doble objetivo: multiestacional y multianual (Chuvieco, 1998). En el primer caso, la dimensión temporal sirve para refinar la discriminación de algunas categorías, que pueden no ser separables espectralmente, pero sí atendiendo a su variedad fenológica. Con este objetivo se seleccionan imágenes adquiridas en distintas estaciones, de acuerdo al calendario fenológico de esas cubiertas. Habitualmente se combinan las bandas de todas las imágenes en un sólo archivo, de tal manera que se enriquezca la clasificación espectral incorporando un componente temporal (Lo *et al.*, 1986). También hay ejemplos de comparación entre clasificaciones realizadas para distintas estaciones, comparando las categorías que en cada una se pueden separar (Schriever y Congalton, 1995). Los resultados suelen mejorar notablemente la clasificación mono-temporal (Mergerson, 1981), siempre que exista un buen ajuste geométrico entre fechas.

El segundo enfoque, que hemos denominado análisis multianual, tiene por objetivo detectar los cambios producidos entre dos o más fechas, para lo que suele partirse de imágenes adquiridas en distintos años, que se comparan visual o digitalmente (Gopal y Woodcock, 1996; Sader y Winne, 1992). En este caso, por contraposición al enfoque multiestacional, se procura que las imágenes sean de la misma época del año, con objeto de aislar más fácilmente lo que las imágenes manifiestan de cambios en el terreno. Un buen ejemplo de este enfoque aparece en el figura 17*, que muestra tres imágenes de la ciudad de Madrid en un intervalo de tiempo entre 8 y 10 años. Se evidencian los notables cambios que ha experimentado la ciudad en las últimas décadas, con la apertura de nuevas vías de comunicación (M-40, M-45, radiales), construcción de grandes zonas residenciales (Sanchinarro-Las Tablas, Valdebernardo, Pozuelo...), y nuevas infraestructuras (aeropuerto, recinto ferial, Mercamadrid...).

3.2. Requisitos previos para el análisis multitemporal

La comparación multitemporal entre imágenes se realiza, en la mayor parte de los casos, comparando píxel a píxel los ND de las distintas fechas. En consecuencia, es necesario eliminar previamente, en la medida de lo posible, cualquier cambio en los ND de la escena que no sea debido a cambios reales en la cubierta. Esto implica asegurar que estemos situados en la misma zona para ambas fechas, y que la variable que estamos comparando se refiera a la misma escala de medida. En definitiva, la comparación temporal requiere una previa corrección geométrica y radiométrica de las imágenes que estamos cotejando.

3.2.1. *Ajuste geométrico*

Para la comparación multitemporal es preciso que las imágenes se ajusten con gran nivel de detalle, ya que de otro modo estaríamos detectando como transformaciones lo que sería sólo fruto de una falta de ajuste entre imágenes. El efecto puede llegar a ser muy grave, especialmente cuando se trata de detectar categorías con una gran variabilidad espacial, como es el caso de las urbanas (Gordon, 1980), dependiendo también de la resolución espacial del sensor (Nelson y Grebowsky, 1982; Roy, 2000). Para sensores de baja resolución espacial, se ha comprobado que hasta un 50 % del cambio observado entre dos imágenes puede deberse a errores de superposición cuando el ajuste entre imágenes tiene un error superior a 1 píxel (Townshend *et al.*, 1992). Varios autores han demostrado que se requieren precisiones de ajuste superiores a 0,2 píxeles para asegurar un error inferior al 10 % en la comparación multitemporal (Dai y Khorram, 1998; Townshend *et al.*, 1992).

Para ilustrar este tema, hemos realizado un sencillo ejercicio, comparando una imagen clasificada consigo misma tras aplicarle un desplazamiento intencional. La clasificación corresponde a una imagen Landsat-TM sobre una zona forestal de la provincia de Valencia. Para simplificar las cosas incluye únicamente cuatro categorías. La clasificación original se desplazó sistemáticamente un píxel hacia el oeste y el sur. El archivo resultado se cruzó con el original mediante una tabulación cruzada, método muy habitual para determinar cambios entre clasificaciones de dos fechas. Como es lógico, en este caso el cambio observado en ese cruce resulta debido exclusivamente al desplazamiento geométrico que hemos introducido, ya que se trata de la misma clasificación en los dos archivos. Como podemos observar en la tabla 7.13*a*, el efecto del desplazamiento es bastante notable, ya que un 34 % de los píxeles de la imagen cambian de clase al realizar la comparación, lo que implica un porcentaje de cambio «ficticio» bastante considerable.

Menos severa resultaría la comparación entre clasificaciones que tuvieran algún tipo de generalización previa, ya que se eliminarían pequeños grupos aislados que introducen mayor ruido cuando existe ese desplazamiento. Para comprobar esto, realizamos una nueva comparación entre la clasificación original y la desplazada, después de aplicarles a ambas un filtro modal de 5 × 5 píxeles. En este caso, los cambios debidos al desplazamiento resultaron mucho menos severos (un 19 % de la imagen: tabla 7.13*b*). Si bien los desplazamientos reales entre imágenes no serán tan sistemáticos como los aquí indicados, el ejercicio nos sirve para entender la impor-

TABLA 7.13*a*. *Efecto del desajuste geométrico para una imagen clasificada*

		Imagen desplazada				
		1	*2*	*3*	*4*	*Total*
Imagen original	1	94	247	42	6	389
	2	251	20.653	9.315	897	31.116
	3	43	9.512	51.449	15.337	76.341
	4	3	755	15.560	27.897	44.215
	TOTAL	269	29.111	80.928	41.470	151.778

tancia de conseguir un ajuste muy preciso entre imágenes, de cara a garantizar la eficacia de la comparación multitemporal. La idea de generalizar las imágenes antes de compararlas resulta evidentemente una precaución a tener en cuenta. Algunos autores han propuesto incluso comparar imágenes previamente segmentadas, de tal forma que se comparen parcelas de una cobertura homogénea en lugar de píxeles individuales (Bruzzone y Fernández-Prieto, 2000).

Como ya indicamos en el anterior capítulo, la mayor parte de las imágenes basan el ajuste geométrico en la localización de una serie de puntos de control imagen-mapa. Para el análisis multitemporal, los puntos se toman entre imágenes, eligiendo una como referencia. En este caso, el proceso de seleccionar puntos comunes resulta más sencillo, ya que son muchos más los rasgos comunes entre dos imágenes, que entre una imagen y un mapa. Para dos imágenes pueden emplearse formas características de la vegetación, del trazado parcelario o la hidrografía, visibles entre imágenes pero que habitualmente no son localizables en el mapa, además de caminos o carreteras. Elegir unos u otros elementos de referencia dependerá, lógicamente, de la resolución espacial de la imagen.

También para el análisis multitemporal resulta de interés el proceso de selección semiautomática de puntos de control. A partir de ventanas móviles en torno a cada punto localizado en la imagen de referencia, el punto en la homóloga se obtiene por correlación entre los ND de ventanas locales en las dos imágenes (Diez de Arribas y Nicolás, 2001; Ortí *et al.*, 1979).

TABLA 7.13*b*. *Comparación entre imágenes desplazadas y filtradas (filtro modal de 5 × 5 píxeles)**

		Imagen desplazada				
		1	*2*	*3*	*4*	*Total*
Imagen original	1	98	100	30	41	269
	2	132	23.556	4.954	387	29.029
	3	39	5.196	66.982	8.681	80.898
	4	0	259	8.962	32.361	41.582
	TOTAL	269	29.111	80.928	41.470	151.778

* La no coincidencia en los totales con la tabla anterior se debe a que no se consideran en ambos casos los píxeles con la clase 0, fruto del desplazamiento.

3.2.2. *Homogeneización radiométrica*

Otro importante problema en la detección de cambios es el producido por las variaciones que introducen las condiciones de observación, situaciones atmosféricas o la calibración del sensor. Estos efectos modifican la signatura espectral de un píxel, aunque se mantenga constante la cubierta. En consecuencia, es preciso homogeneizar los ND de las imágenes que intervienen en el análisis. Para ello, puede optarse por un doble enfoque:

1. Calibrar los ND de modo absoluto, convirtiéndolos a medidas de reflectividad o temperatura del suelo.
2. Equiparar los ND entre imágenes.

En el primer caso, es preciso acudir a los modelos de conversión a parámetros físicos vistos previamente, incorporando los parámetros de corrección atmosférica y de iluminación más propios para cada fecha. En el segundo enfoque basta una corrección relativa entre fechas, ya que sólo se trata de facilitar las comparaciones entre ellas. Con esta óptica, los métodos de corrección propuestos se basan en situar una serie de píxeles de radiancia constante entre fechas, preferiblemente que recojan áreas de baja reflectividad (sombras, aguas claras y profundas) y alta reflectividad (suelos descubiertos, estacionamientos, pistas de aterrizaje). A partir de los ND de esos píxeles, pueden estimarse unos coeficientes de sesgo y ganancia, para cada banda, que permitan corresponder los ND entre fechas distintas. El método se ensayó con buenos resultados en un estudio multitemporal sobre la Albufera de Valencia (Caselles y López, 1989), comparándolo con modelos atmosféricos estándar (Tanre *et al.*, 1986). La viabilidad de estas correcciones para homogeneizar las condiciones atmosféricas entre imágenes también se ha demostrado en el marco de la estimación de cosechas (Hill y Sturm, 1991) y en el inventario forestal, facilitando ajustes con una correlación superior a 0,98 (Coppin y Bauer, 1994).

Puesto que la variación temporal entre píxeles puede alterar esos coeficientes de regresión, otros autores han propuesto utilizar los ND más oscuros y más claros entre fechas, obtenidos a partir de los componentes de brillo y verdor de la transformación *(tasseled cap)* (7.1.3):

$$ND_{c,\,k} = s_k\, ND_k + g_k \qquad \{7.48\}$$

esto es el ND corregido en la banda k se estimaría a partir de unos coeficientes de sesgo y ganancia para esa banda, que se obtienen a partir de:

$$s_k = (ND_{cl,\,r,\,k} - ND_{os,\,r,\,k}) \,/\, (ND_{cl,\,c,\,k} - ND_{os,\,c,\,k}) \qquad \{7.49\}$$

y

$$g_k = (ND_{os,\,r,\,k}\, ND_{cl,\,c,\,k} - ND_{os,\,c,\,k}\, ND_{cl,\,r,\,k}) \,/\, (ND_{cl,\,c,\,k} - ND_{os,\,r,\,k}) \qquad \{7.50\}$$

donde $ND_{os,\,r,\,k}$ y $ND_{cl,\,r,\,k}$ indican el ND medio de los píxeles más oscuros y más claros, respectivamente, de la imagen de referencia, y $ND_{os,\,c,\,k}$ y $ND_{cl,\,c,\,k}$ lo mismo en

la imagen a corregir. El método se comprobó muy sólido para homogeneizar el efecto atmosférico entre imágenes para un estudio multitemporal. Caso de que la imagen de referencia se hubiera corregido atmosféricamente, el método también sirve para eliminar el aporte atmosférico en las imágenes de otras fechas, obteniendo coeficientes de correlación muy adecuados con correcciones atmosféricas de precisión (Hall *et al.*, 1991). Otros autores proponen, en ausencia de superficies invariantes entre fechas, utilizar aquellos que cuenten con NDVI más bajos y más altos (Hill y Sturm, 1991).

Recientemente se ha propuesto un método de corrección multitemporal que ha intentado estandarizar los procedimientos de ajuste entre imágenes (Heo y Fitzhugh, 2000). En primer lugar, se establecen unos criterios bastante estrictos para seleccionar las superficies como invariantes entre fechas. Debe tratarse de áreas con la misma elevación, para que el espesor atmosférico sea similar; con similar topografía, preferentemente plana, para que los ángulos de iluminación entre fechas sean similares; con poca vegetación, para minimizar los efectos de los cambios fenológicos; que mantengan el patrón espacial, y que recojan un amplio rango de ND para que la regresión sea consistente. Los autores proponen eliminar puntos con residuales muy altos, pues puede tratarse de áreas de cambio o afectadas por algún tipo de ruido, y contemplan la posibilidad de utilizar distintos puntos en cada banda para considerar el distinto sesgo que puedan incluir. Sugieren utilizar píxeles concretos en lugar de promedios de ventanas de 3 × 3 píxeles.

3.3. Técnicas para el análisis estacional

Cuando el fin último del análisis temporal es determinar perfiles estaciones en las cubiertas vegetales de interés, habitualmente la interpretación se realiza sobre las distintas fechas de modo simultáneo. Por ejemplo, si se pretende mejorar la clasificación de un determinado cultivo se acude a imágenes de momentos clave dentro de su ciclo fenológico, que permitan separarlo con nitidez de otros cultivos espectralmente similares (Prados, 1995). La clasificación, en este sentido, se realiza con todas las fechas simultáneamente, ya que se pretende caracterizar una categoría a partir de curvas espectro-temporales. Como el incremento en el número de fechas implica aumentar el volumen de cálculo, ha sido bastante frecuente aplicar previamente alguna técnica de compactación, como el análisis de componentes principales o los índices de vegetación. De esa forma, pueden procesarse sólo las bandas con mayor contenido informativo, evitando redundancias innecesarias (Maselli *et al.*, 1996).

La figura 7.58 muestra algunas posibilidades de este enfoque estacional. Se recogen tres imágenes de la misma banda espectral (SWIR), adquiridas en primavera, verano e inicios del otoño para un sector próximo al parque nacional de Cabañeros (Ciudad Real-Toledo). Puesto que en el SWIR hay una fuerte absortividad de la vegetación, las zonas cubiertas por cultivos vigorosos aparecen en tonos oscuros. Se evidencia el paso de cultivo a suelo en las imágenes de mayo y julio para los cultivos de primavera (*a*), y el proceso inverso para los de regadío (*b*). También puede observarse la variación interanual de la lámina embalsada (*c*), y la dinámica de pastizales (*d*), entre otros elementos de interés.

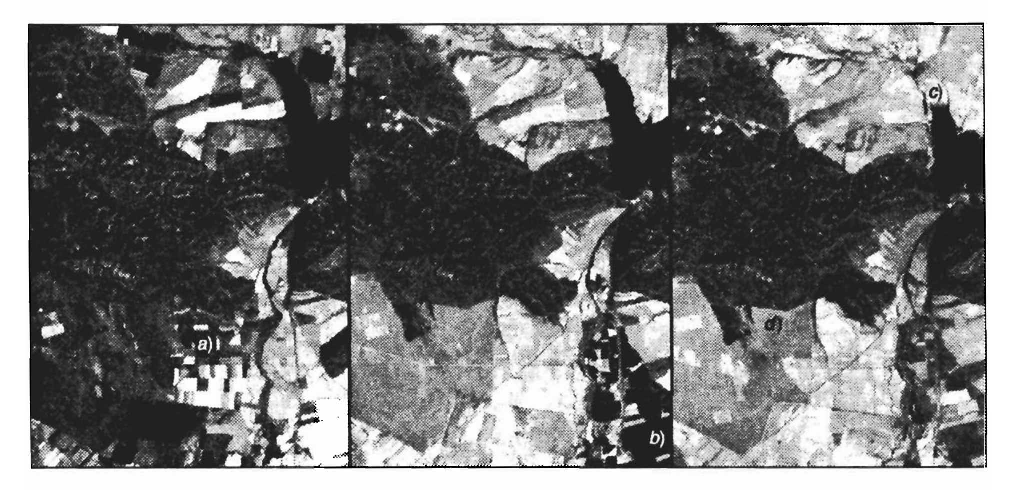


FIG. 7.58. *Tres imágenes correspondientes a la región adyacente al Parque Nacional de Cabañeros. De izquierda a derecha: mayo 1998, julio 1998 y septiembre 1997. Se observa la dinámica estacional de cultivos de secano (*a*), regadío (*b*), áreas inundables (*c*) y pastizales (*d*).*

Un aspecto específico del análisis estacional es el seguimiento de las condiciones ambientales en un ciclo corto de tiempo. En este ámbito entraría el análisis de fenómenos atmosféricos o de las condiciones vitales de la vegetación, por ejemplo de cara a estimar demandas de riego, predicciones de rendimientos del cultivo o situaciones de peligro de incendios. Este análisis estacional puede abordarse con pocas imágenes (p. ej., una por estación), o con una serie más numerosa, intentando recoger las variaciones temporales de ciclo inmediato. Para este tipo de análisis suelen emplearse imágenes de alta frecuencia temporal, como son las adquiridas por los sensores AVHRR, VEGETATION o MODIS. Aunque su resolución espacial es baja, al tratarse de imágenes diarias permiten reconstruir con mucho detalle las variaciones en parámetros fisiológicos de las plantas, la dinámica de la cubierta de nieve, de las láminas regadas, o de las variaciones en temperatura. Además, la mayor parte son de libre adquisición, por lo que pueden conseguirse series largas de datos con una inversión pequeña. Esto les permite abordar clasificaciones con cierto nivel de detalle temático, a partir de las series multitemporales. Por ejemplo, a partir de estas imágenes se han realizado cartografías de cobertura del suelo a escala global, tanto para AVHRR (Loveland *et al.*, 2000; Tucker *et al.*, 1985), como para VEGETATION (Bartholome y Belward, 2005; Latifovic *et al.*, 2004), y MODIS (Friedl *et al.*, 2002; Price, 2003). La integración de estas imágenes con información meteorológica puede enriquecer notablemente nuestro conocimiento sobre la actividad fisiológica de las plantas, de cara a mejorar los modelos existentes de productividad vegetal (Chladil y Nunez, 1995; Nemani *et al.*, 1993), o plantear estimaciones de su estado hídrico (como ya vimos en 7.1.1.3). El gran impacto de estos estudios explica que se hayan puesto a disposición pública series multitemporales para el análisis de tendencias. Las más conocidas son las del archivo histórico de imágenes AVHRR (Eidenshink, 2006; Latifovic *et al.*, 2005), que plantean mayores problemas de calibración y corrección

geométrica que las más recientemente adquiridas por MODIS (Townshend y Justice, 2002).

La figura 18* incluye una serie estacional de imágenes AVHRR adquiridas sobre un sector del norte de Canadá, comprendido entre los paralelos 52 y 64º N. Permite observar el interés de analizar las variaciones estacionales en las cubiertas vegetales (nótese el rojo más intenso de las praderas situadas en el vértice SW según avanza el verano), las cubiertas de nieve (tundra situada al NE o bordes del lago Atabasca, al NW), y el bosque boreal (franja NW-SE).

En el análisis de series temporales de imágenes suelen emplearse índices relativos, que permiten medir las condiciones de un momento frente a una tendencia tipo, ya sea el máximo anual o un promedio de una serie larga. Uno de los más sencillos es el verdor *(greenness)*, definido como (Kogan, 1990):

$$\text{VERDOR}_i = \frac{\text{NDVI}_i - \text{NDVI}_{min}}{\text{NDVI}_{max} - \text{NDVI}_{min}} \cdot 100 \qquad \{7.51\}$$

donde NDVI*i* indica el valor del índice de vegetación para el período *i*, y NDVI_{max} y NDVI_{min} los valores máximos y mínimos de los índices en cada píxel para la serie de imágenes analizada. El verdor, en principio, está más relacionado que el NDVI absoluto con los cambios debidos a las condiciones atmosféricas, ya que se enfatiza el cambio temporal en el vigor y densidad vegetal frente al cambio espacial que también está incluido en el valor absoluto del NDVI (fig. 7.59). Esa variación temporal se considera precisamente en función de los umbrales de variación propios de cada píxel. Este índice se ha comprobado de gran interés en la estimación del peligro de incendios (Burgan *et al.*, 1998) o condiciones de sequía (Peters *et al.*, 1991).

También se ha propuesto calcular el decremento temporal de los índices de vegetación, de cara a medir el efecto acumulado de las variaciones estacionales en el vigor vegetal. Una manera sencilla de obtener este índice es calcular la pendiente de la línea que define la evolución temporal del índice (Illera *et al.*, 1996):

$$PT_i = \frac{\sum_{i=1,n} (\text{NDVI}(t_i) - \text{NDVI}(t_{i-1}))}{t_i - t_{i-1}} \qquad \{7.52\}$$

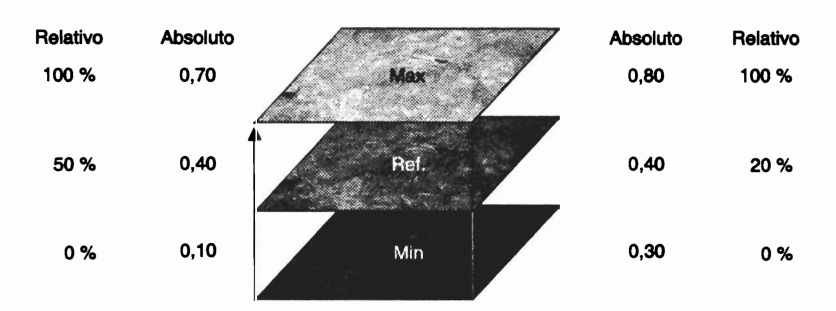


FIG. 7.59. *Interés de los índices de cambio relativo para determinar variaciones estacionales.*

donde PT_i indica la pendiente del período i, y t_i el período de tiempo considerado. Este índice parece bastante relacionado con las variaciones del vigor vegetal desde la primavera hasta el verano, identificando situaciones de deterioro en la vegetación (López *et al.*, 1991).

Otro índice de interés es el análisis de anomalías temporales, esto es la determinación de las desviaciones entre el ND de un píxel para un determinado período y el promedio de la serie histórica para ese mismo píxel:

$$\Delta t_i = \frac{\mathrm{NDVI}(t_i)}{\mathrm{NDVI}(\bar{t})} \cdot 100 \qquad \{7.53\}$$

donde NDVI (t) indicaría el valor del índice correspondiente a un determinado período i y NDVI ($\bar{t}$) el valor medio para ese período, para un conjunto de años suficientemente largo. Esto permitiría ver si las tendencias de un momento determinado son las esperables o se registran valores anómalos (ya sean superiores o inferiores a la tendencia promedio). Esta técnica es la base para el seguimiento de las condiciones de sequía en los cultivos que se realiza operativamente en varios países (Gonzalez-Alonso *et al.*, 2004), en algunos de ellos auspiciado por la FAO.

Cualquiera de los índices arriba indicados también puede emplearse para las variaciones de temperatura o de cualquier otro índice espectral. En el ámbito del estudio del calentamiento global del planeta, este tipo de datos resulta también muy significativo (fig. 19*).

Otra técnica utilizada para series temporales de imágenes es el ACP. En este caso, se aplica la técnica sobre la serie temporal completa, considerando cada fecha como una banda. Los primeros componentes de una serie normalmente indican una situación promedio, la tendencia estable, mientras los componentes secundarios informan sobre aspectos del cambio que se observe en el período. A partir de componentes principales estandarizados, se abordó un interesante análisis de las tendencias de la vegetación en África, sobre una serie temporal de 36 imágenes que cubrían todo el continente. Se observó que los primeros componentes recogían la tendencia promedio, mientras los restantes marcaban algunos rasgos de interés en la fenología de la vegetación, detectando eventos anómalos de sequía, e incluso algunos errores en la adquisición de las imágenes, difícilmente detectables sobre los valores originales (Eastman y Fulk, 1993).

3.4. TÉCNICAS PARA LA DETECCIÓN DE CAMBIOS

Los estudios de detección de cambios pueden aplicarse a una gran variedad de disciplinas (Mouat *et al.*, 1993). Tienen por objeto analizar qué rasgos presentes en un determinado territorio se han modificado entre dos o más fechas, de cara a evaluar los impactos de un determinado fenómeno, ya sea continuo o esporádico (Observatorio de la Sostenibilidad, 2006). Un buen ejemplo del interés de este enfoque temporal es el *Atlas of Our Changing Environment* editado por el programa de medioambiente de Naciones Unidas (UNEP: http://na.unep.net/OnePlanetManyPeople/index.php, último acceso mayo de 2008).

Como en otras fases de la interpretación de imágenes, la localización de esos cambios suele implicar un compromiso entre los errores de omisión y de comisión, esto es desechar un cambio que realmente existe o detectar un cambio que no ha ocurrido, respectivamente. En el primer caso tendríamos un carencia de información y en el segundo una falsa alarma. La importancia de uno u otro tipo de errores marcará, en buena medida, la técnica más conveniente a utilizar en cada caso. En algunos estudios el objetivo preferente será evitar las falsas alarmas (aplicar tratamientos sobre un cultivo que no esté afectado por una plaga, por ejemplo), pero lo más habitual será poner más bien el énfasis en reducir las omisiones (por ejemplo, resulta preferible asistir a una zona que no ha sido realmente afectada por una inundación, que arriesgarse a que no se atiendan algunas efectivamente dañadas).

Otro aspecto de interés en el análisis de cambios hace referencia al tipo de transformaciones que pretenden delimitarse en una imagen, según se transformen los rasgos espectrales o espaciales de una imagen (Robin, 1998). Los primeros son los que se detectan más habitualmente en teledetección y hacen referencia a modificaciones en la señal reflejada o emitida por una determinada parcela, ya sea como consecuencia de cambios en la cubierta, ya debido a alteraciones en su densidad o estado fenológico. Por ejemplo, un nuevo cultivo en la misma explotación implica mantener la estructura espacial pero alterando la respuesta espectral. Por su parte, los cambios espaciales implican transformaciones de la forma o el tamaño de las parcelas, aunque pueda mantenerse su cobertura previa (por ejemplo, igual cultivo sobre una parcela más grande o pequeña). Estos últimos están menos desarrollados en teledetección, pero se están comenzando a analizar gracias a las técnicas de segmentación multitemporal (Bruzzone y Fernández-Prieto, 2000; Hazel, 2001; Smits y Annoni, 1999).

Intentando resumir la amplia relación de estudios que utilizan técnicas de análisis multitemporal (Eastman *et al.*, 1994; Mouat *et al.*, 1993; Singh, 1986), podemos establecer dos grupos, según utilicen imágenes continuas o ya clasificadas. En el primer caso, se emplean técnicas cuantitativas: diferencias, regresión, componentes principales, etc., mientras en el segundo se emplean tablas de contingencia o comparaciones por pares. A continuación, vamos a repasar las técnicas más empleadas, presentando algunos ejemplos prácticos de su utilización.

3.4.1. *Composiciones de color multitemporales*

En esta técnica se trata de detectar las áreas de cambio mediante el análisis visual de imágenes en color provenientes de varias fechas. Ya hemos visto en esta obra que cualquier sistema de ADI permite obtener mezclas en color de tres bandas de una imagen, aplicando a cada una de ellas uno de los cañones de color disponibles (*R*, *V*, *A*). Si la imagen resultante aparece en tonos de color es debido a que las tres bandas que se combinan presentan comportamientos espectrales diferentes. Dicho de otra manera, si vemos un píxel en color es porque cuenta con un ND distinto en las tres bandas que estamos utilizando (o al menos en dos de ellas), ya que de otra manera se vería en tonos de gris.

Si en lugar de combinar tres bandas distintas del espectro, mezclamos tres fechas de la misma banda, estaríamos viendo en tonos de color aquellos píxeles que tuvieran distintos ND en alguna de ellas, mientras aparecerían en tonos de gris los

que no hubieran cambiado entre fechas. La interpretación del color resultante dependerá, lógicamente, de qué bandas combinemos y en qué orden temporal. Para una composición de dos fechas, resulta frecuente que se aplique el cañón rojo a la primera fecha y el verde a la segunda, dejando el azul vacío o repitiendo la segunda fecha (fig. 20*), así se simplificaría la interpretación del color resultante. Con este criterio, aparecerían en tonos grises las áreas estables, en rojos las zonas que hayan reducido su ND entre las dos fechas y en cian ($V + A$) las que lo hayan ganado. El sentido de la transformación que muestren esos colores dependerá de qué bandas estemos comparando entre fechas. En caso de que estemos combinando el NDVI de los dos períodos (manteniendo el criterio de rojo a la primera fecha y verde + azul a la segunda), los tonos rojos revelarían decrementos de NDVI (en definitiva, pérdidas de cobertura vegetal debidas a talas, cosechas, incendios, o variaciones estacionales), mientras los cian indicarían aumentos de NDVI (ganancias de vegetación, por ejemplo, a causa de la puesta en cultivo de suelos previamente descubiertos o por desecación de una lámina de agua). Para el caso de la figura 20*, se comparan imágenes del NDVI de dos estaciones distintas (agosto de 1999 y marzo de 2000) para la zona de Torrelaguna. Como puede observarse, los cambios entre fechas son muy notables. Los tonos rojos indican pérdida de NDVI entre los dos años, y en este caso se relacionan con los caducifolios del pie de la sierra y de los márgenes de los ríos, que no tienen hojas en la segunda fecha (marzo), mientras los cian se relacionan con aumento de NDVI, que corresponde a las áreas de pastizal, que están secas en la primera fecha y vigorosas en la segunda.

Para hacer comparaciones temporales en color también pueden usarse los ND originales o los valores de reflectividad de alguna de las bandas de la imagen. En ese caso, la interpretación diferirá de la indicada para la comparación entre NDVI. La tabla 7.14 recoge un ejemplo de posible interpretación cruzada entre composiciones multitemporales en color de dos bandas distintas (la IRC y SWIR). Como puede analizarse, los incrementos o decrementos en una banda tendrán significados distintos según las tendencias observadas en otra/otras. Por lo demás, el método resulta bastante sencillo y tiene la ventaja de incorporar el conocimiento y los criterios de análisis del intérprete, lo que resulta muy ventajoso en categorías urbanas (Martin, 1989; Sader y Winne, 1992).

TABLA 7.14. *Modelo de interpretación para dos composiciones multitemporales en el IRC y el SWIR*

		IRC Color en pantalla		
Banda espectral		*Tonos rojos*	*Tonos verdes*	*Tonos amarillos*
SWIR Color en pantalla	*Tonos rojos*	Suelo a agua	Suelo a vegetación	Suelo seco a húmedo
	Tonos verdes	Vegetación a suelo	Agua a suelo	Suelo húmedo a seco
	Tonos amarillos	Vegetación senescente	Vegetación emergente	Sin cambios

(Los tonos corresponden a lo que se observaría en una composición multitemporal de cada banda, asumiendo que el rojo se aplica a la primera fecha y el verde a la segunda.)

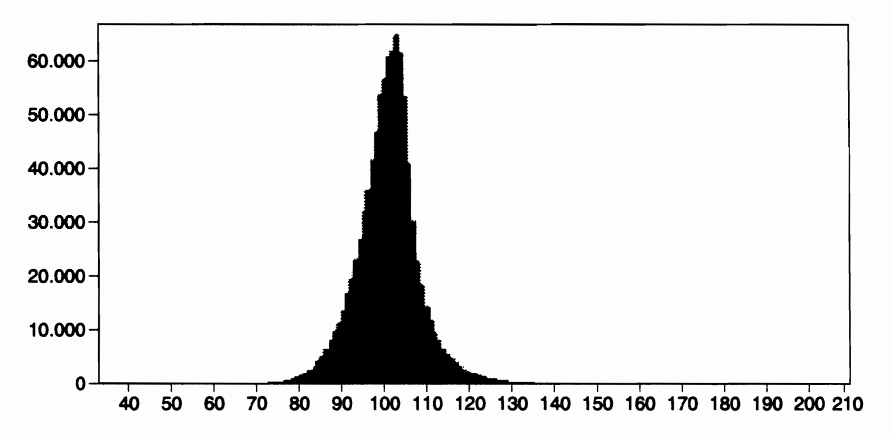


FIG. 7.60. *Histograma teórico de una imagen de cambios.*

3.4.2. *Diferencia entre imágenes*

Una simple resta entre las imágenes de dos fechas, previamente homogeneizadas radiométrica y geométricamente, permite discriminar aquellas zonas que han experimentado cambios entre esas fechas. Las zonas estables presentarán un valor cercano a cero, mientras las que hayan experimentado cambios ofrecerán valores significativamente distintos a cero (positivos o negativos). Si el equipo de ADI no permite visualizar valores negativos, conviene añadir al cálculo una constante para evitar éstos. En resumen:

$$ND_c = ND_{t2} - ND_{t1} + C \qquad \{7.54\}$$

donde ND_c indica el ND correspondiente a la imagen de cambios, ND_{t1} y ND_{t2} los correspondientes a las imágenes del primer y segundo período respectivamente, y C es una constante para evitar valores negativos.

Como fruto de este cálculo se obtiene una imagen de cambios, que presentará valores bajos o negativos (tonos oscuros) para las zonas que hayan reducido su ND, mientras los más altos (tonos claros) corresponderán a aquéllas que hayan ganado y los intermedios indicarán zonas estables. El cálculo puede realizarse sobre los ND de alguna de las bandas originales (en ocasiones se ha utilizado la banda roja: (Pilon *et al.*, 1988), aunque es más frecuente aplicar esta operación sobre índices de vegetación. En este caso, el valor de la diferencia nos permite señalar las zonas que han perdido o ganado vigor vegetal, o simplemente las que han cambiado su cobertura por efecto de la rotación, talas o incendios (Coppin y Bauer, 1994; Martín y Chuvieco, 1995). El histograma de esa imagen de cambios suele revelar un perfil gausiano, con las máximas frecuencias para las zonas estables (en el centro del histograma) y las dinámicas ocupando las colas de la distribución (fig. 7.60).

Las figuras 7.61 y 7.62 incluyen dos ejemplos del empleo de esta técnica para detectar cambios en la vegetación. En ambos casos se incluye el NDVI como variable de entrada. El primer ejemplo, tomado de un estudio de deforestación en los Llanos Occidentales venezolanos (Chuvieco *et al.*, 2002; Vargas, 2000), revela las zo-

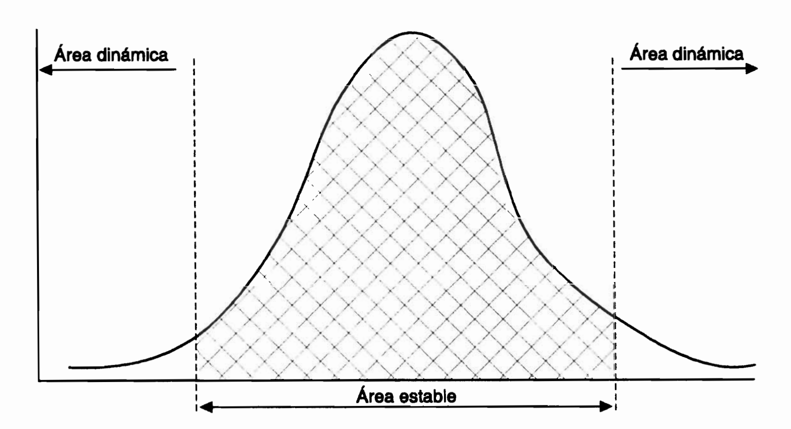


FIG. 7.61. *Diferencias entre NDVI de 1997 y 1993 para detectar procesos de deforestación.*

(NDVI 1993)

(NDVI 1997)

Diferencia (1997-1993)

Histograma de la imagen de diferencias

f

−1,42 −1,18 −0,93 −0,69 −0,44 −0,20 0,05 0,29 0,54 0,78 1,03

FIG. 7.62. *Imágenes de NDVI antes (a) y después del fuego (b) en el área de Buñol. Diferencias (c) y cocientes (d) entre ambas imágenes, que evidencian el área quemada.*

nas que han perdido cubierta forestal entre 1993 y 1997, período de especial intensidad de este fenómeno. Por su parte, la figura 7.62 muestra la diferencia entre imágenes de NDVI adquiridas antes y después de un incendio en el interior de Valencia (próxima a Buñol). Se observa en tonos oscuros las zonas donde el decremento de NDVI ha sido más intenso, que coincide bastante bien con las zonas quemadas, mientras los grises medios corresponden a zonas que no han alterado su cubierta vegetal entre ambas fechas.

3.4.3. *Cocientes multitemporales*

La diferencia entre imágenes resulta una técnica sencilla para observar cambios entre fechas, si bien tiene el problema de reflejar únicamente las diferencias absolutas, pero no ofrece la significación del cambio frente a los valores originales. Por ejemplo, una reducción de 20 ND entre fechas puede significar una alteración significativa si el ND original era 40, mientras resultará menos importante si el ND de la primera fecha era de 200. Para subsanar ese problema, puede ser más conveniente en ocasiones emplear cocientes multitemporales, que ofrecen una valoración relativa del cambio:

$$ND_c = (ND_{t2} / ND_{t1}) \times C \qquad \{7.55\}$$

con el mismo significado de la fórmula anterior, o también los índices multitemporales normalizados:

$$ND_{i,j,c} = ((ND_{t2} - ND_{t1}) / (ND_{t2} + ND_{t1})) + 1) \times 127 \qquad \{7.56\}$$

en este caso se añade al índice 1 y se multiplica el resultado por 127 para escalar el resultado entre 0 y 254.

Los cocientes multitemporales se han empleado en inventarios agrícolas (Lo *et al.*, 1986) y forestales (Howarth y Wickware, 1981; Singh, 1986). En aplicaciones ambientales es frecuente que estos cocientes se calculen a partir de los índices de vegetación, lo que permite simplificar la variación vegetal en una sola banda. En este contexto, se han empleado con gran éxito los cocientes en estudios de deforestación (Grover *et al.*, 1995; Singh, 1986), e incendios forestales (Kasischke *et al.*, 1993; Martín y Chuvieco, 1995).

El principal problema de los cocientes multitemporales es su carácter no simétrico. En otras palabras, el resultado es dependiente de qué fecha elijamos para el numerador. Una reducción a la mitad del ND (p. ej., de 100 a 50) ofrece un valor de 2 o de 0,5 según el orden en que introduzcamos las fechas. En definitiva, implica una transformación no lineal de las relaciones temporales. Para solucionar este problema, algunos autores recomiendan realizar una conversión logarítmica del resultado (Eastman *et al.*, 1994).

La figura 7.62*b* nos ofrece una imagen del cociente normalizado de los NDVI correspondientes al incendio de Buñol, junto a la imagen de diferencias simples. En este caso, la delimitación del área quemada es bastante clara y similar en ambas técnicas, observándose tanto el perímetro propiamente dicho, como sectores dentro de

la mancha quemada donde el incendio fue menos severo o había menor presencia vegetal.

3.4.4. *Componentes principales*

Como antes señalamos, en el caso de aplicaciones multitemporales el ACP se utiliza de un modo un tanto particular, ya que no se pretende retener la información común entre fechas, sino precisamente la que cambia. Para aplicar esta técnica en la detección de cambios se genera un archivo multitemporal con las bandas correspondientes a las dos fechas, sobre el que se aplica el ACP. En este caso, los primeros componentes resultantes del análisis no son los más interesantes, ya que recogerán la dimensión de estabilidad en la imagen. Por su parte, los componentes secundarios ofrecen la información no común: el cambio, que es precisamente lo que más interesa en este contexto.

El ACP se ha utilizado frecuentemente en detección de cambios. Para 2 imágenes MSS (4 bandas cada una), se ha comprobado que los componentes 3, 4 y 5 recogen habitualmente el cambio entre fechas (Byrne *et al.*, 1980). Algunos autores interpretan que los dos primeros componentes de ese conjunto de 8 ofrecen información sobre el brillo y el verdor estables en la imagen, mientras el 3.° indica cambio en el brillo y el 4.° cambio en el verdor (Fung y LeDrew, 1987; Fung y LeDrew, 1988; Ingebritsen y Lyon, 1985). También en ocasiones se han comparado los componentes principales deducidos para cada fecha, por separado, aplicando una diferencia o cociente entre ellos (Coppin y Bauer, 1994; Singh, 1986).

En la tabla 7.15 aparecen los autovalores y autovectores correspondientes a la comparación multitemporal de dos imágenes adquiridas en el área de Torrelaguna, que venimos utilizando en este capítulo. Aquí se han mezclado las bandas 1, 2, 4, 5 y 7 de dos pequeñas ventanas extraídas de dos imágenes tomadas con 16 años de diferencia (verano de 1984 y primavera de 2000), por los sensores TM y ETM+, respectivamente.[2] Los cuatro primeros CP suman más del 95 % de la variación, por lo que se puede afirmar que recogen lo más sustancial de ambas fechas. La interpretación de los componentes se realiza de forma similar a como comentamos en el epígrafe 7.1.4, si bien en este caso además del contraste espectral que marquen los coeficientes también hay que observar el temporal. El primer CP corresponde claramente al sustrato común entre todas las bandas y las dos fechas, ya que todos los coeficientes son positivos, lo que podemos simplificar denominándolo «brillo estable». El segundo corresponde con nitidez al cambio entre fechas, ya que los coeficientes son negativos en la primera imagen y positivos en la segunda. Ya que no se hace una distinción entre bandas, dentro de cada fecha, podemos denominar a este componente como «cambios en el brillo», o mejor aún, considerando el signo de los coeficientes, «incremento de brillo». El tercero muestra para las dos fechas el contraste entre el IRC y las demás bandas, por lo que podemos calificarlo como «verdor estable». Nótese que los coeficientes son algo más altos en el IRC de la segunda fecha por tratarse de una imagen de primavera y, por tanto, contar con mayor vigor vegetal

2. La banda 3 de la imagen TM de 1984 estaba dañada, por lo que no se ha podido utilizar en este análisis. No obstante su variación espectral se cubre bastante bien con las bandas 2 y 1.

TABLA 7.15. *Autovectores de los componentes principales para las imágenes de Torrelaguna (TM = 1984; ETM = 2000)*

	Autovalor	*Varianza*	*TM1*	*TM2*	*TM4*	*TM5*	*TM7*	*ETM1*	*ETM2*	*ETM4*	*ETM5*	*ETM7*
1	2.045,73	70,71 %	0,193	0,153	0,305	0,623	0,281	0,087	0,129	0,376	0,386	0,256
2	350,64	12,12 %	–0,145	–0,113	–0,264	–0,460	–0,245	0,128	0,180	0,380	0,527	0,392
3	285,31	9,86 %	–0,097	–0,038	0,238	–0,075	—0,215	–0,167	–0,141	0,766	–0,210	–0,449
4	88,63	3,06 %	–0,365	–0,271	–0,648	0,394	0,220	–0,248	–0,261	0,106	0,122	–0,116

que en la primera. Finalmente, el cuarto componente resulta más complicado de interpretar, pues si bien se refiere a cambio entre fechas (los coeficientes tienen signos distintos en el IRC y en una de las bandas del SWIR) no es nítido a qué tipo de contraste especial está refiriéndose, tal vez a la transición de vegetación seca a vigorosa.

La figura 7.63 proporciona una valoración gráfica del sentido de estos componentes. Aparece en la parte superior la banda 4 de las dos fechas, para que se nos facilite la observación visual de los cambios. A continuación se sitúan los 4 primeros CP del archivo multitemporal. Se confirma que el primero recoge la información estable a las dos fechas, con la excepción del sector del embalse del Vellón que aparece parcialmente desecado en la segunda fecha y no se aprecia en la imagen estabilidad, posiblemente por el fuerte peso de la absorción del agua en la primera. En el segundo, que habíamos denominado «incremento de brillo», esa zona se observa con gran nitidez, ya que es precisamente la que presenta los valores más altos (mayor incremento de brillo entre las dos fechas, al pasar de agua a vegetación). Asimismo, hemos destacado con círculos dos recientes urbanizaciones en construcción (o recientemente construidas), que ofrecen valores más altos de brillo por pasar de

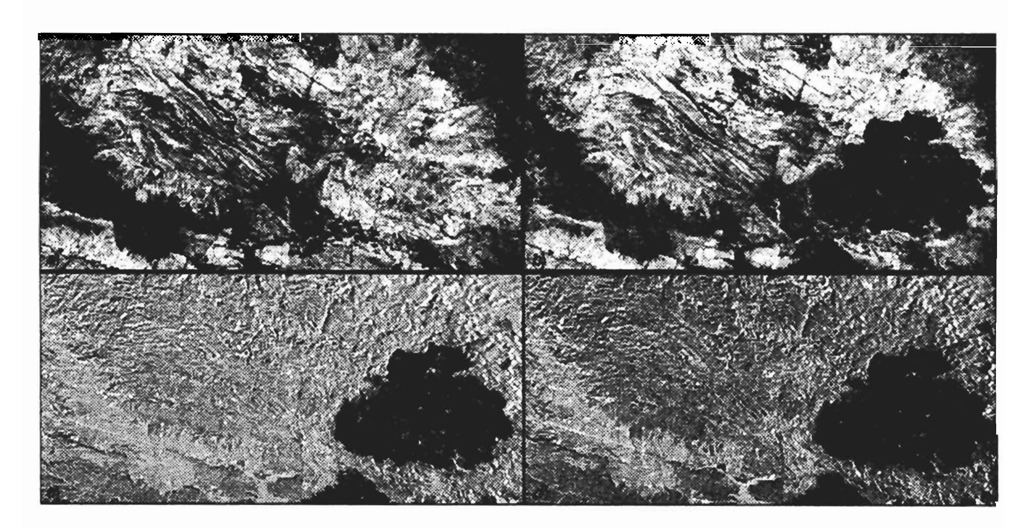


FIG. 7.63. *Imágenes originales de Torrelaguna: (a) Banda 4, 1984; (b) Banda 4, 2000. Cuatro primeros CP multitemporales (c, d, e, f) de ambas imágenes. En el segundo componente se observan algunos cambios en el brillo de la imagen.*

vegetación a suelo construido. El tercer componente muestra los sectores de vegetación más vigorosa entre fechas, que corresponden generalmente a pastizales. Finalmente, el cuarto nos informa de cambios que se han producido en el vigor vegetal, de áreas de vegetación seca a vigorosa. Esta dimensión nos permite caracterizar con claridad algunas zonas residenciales ya consolidadas, que han pasado de vegetación arbórea-arbustiva a especies ornamentales, con mayor vigor, no obstante la interpretación de este componente, como hemos visto, resulta un tanto confusa.

3.4.5. *Regresión*

Como es bien sabido, las técnicas de regresión se emplean para estimar valores de una variable de interés a partir de otra que está fuertemente asociada con ella. Esa asociación se mide a partir de unas observaciones comunes a ambas variables, a partir de las cuales se ajusta una función que las relaciona numéricamente. En el marco de la corrección geométrica de imágenes, ya tuvimos ocasión de comentar esta técnica, por lo que aquí sólo nos detendremos en su aplicación al análisis de cambios.

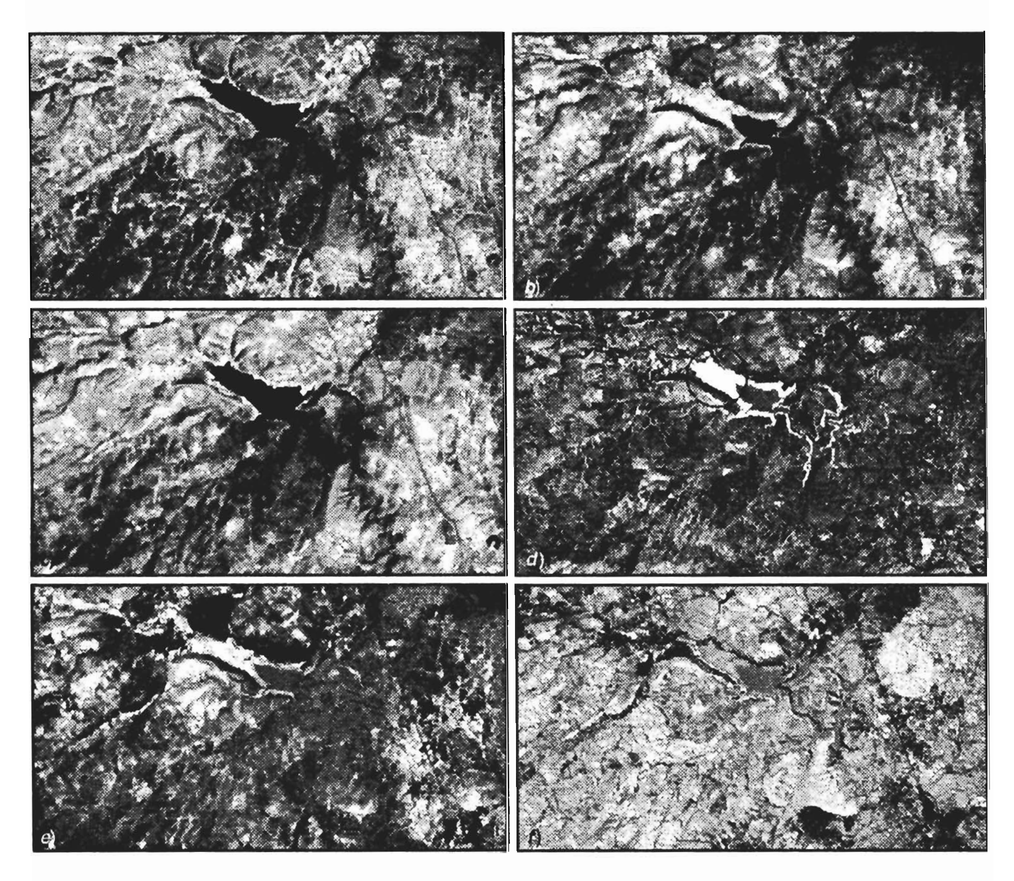


FIG. 7.64. *Esquema de la regresión multitemporal.*

En este contexto, las técnicas de regresión se utilizan para estimar cuáles serían los ND de la imagen de la segunda fecha caso de que no hubiera habido cambios entre ellas. En definitiva, se considera que la segunda fecha es una función de la primera, y que toda desviación de la función estimada estaría representando el cambio. Siguiendo la notación convencional, los ND de la segunda fecha se estiman a partir de la primera, utilizando:

$$\hat{ND}_{t2} = a + b \cdot \mathrm{ND}_{t1} \qquad \{7.57\}$$

donde $\hat{ND}_{t2}$ estaría indicando el valor estimado de la segunda fecha (*t*2), calculado a partir de los coeficientes de regresión (*a*, *b*) sobre los ND de la primera fecha (*t*1). Estos valores estimados serán muy similares a los reales de la segunda fecha, siempre que no se haya producido cambio, sirviendo además para homogeneizar la radiometría entre las dos fechas. En caso de que hayan ocurrido cambios entre imágenes, los ND reales de la segunda fecha presentarán valores alejados de los estimados por la regresión, o lo que es lo mismo contarán con altos residuales:

$$\mathrm{ND}_c = \mathrm{ND}_{t2} - \hat{ND}_{t2} \qquad \{7.58\}$$

Los coeficientes de regresión pueden calcularse para todos los ND de la imagen o a partir de un muestreo. En el primer caso, puede violentarse algún requisito de la regresión, ya que los ND presentan una clara autocorrelación espacial (Congalton, 1988; Eastman *et al.*, 1994), además de complicar los cálculos. La regresión multitemporal se ha utilizado para determinar cambios en áreas urbanas (Molina y Chuvieco, 1997), y forestales (Martín y Chuvieco, 1995), con buenos resultados. También se ha empleado la regresión logística para determinar cambios entre fechas, empleando como variables de entrada las bandas de las dos imágenes consideradas (Pu y Gong, 2004; Silva *et al.*, 2004).

Un ejemplo de la aplicación de este tipo de técnicas aparece en la figura 7.65 que muestra una comparación entre la banda ETM+3 de una imagen de Madrid adquirida en marzo de 2000 y la estimada a partir de la TM-3 de agosto de 1992, así como la imagen de residuales. Se observan con claridad los desarrollos urbanos que

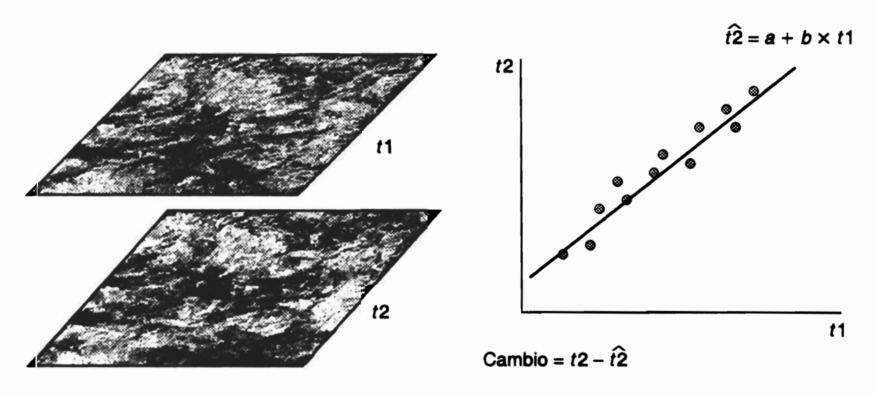


FIG. 7.65. *Regresión multitemporal sobre las imágenes de Madrid.*

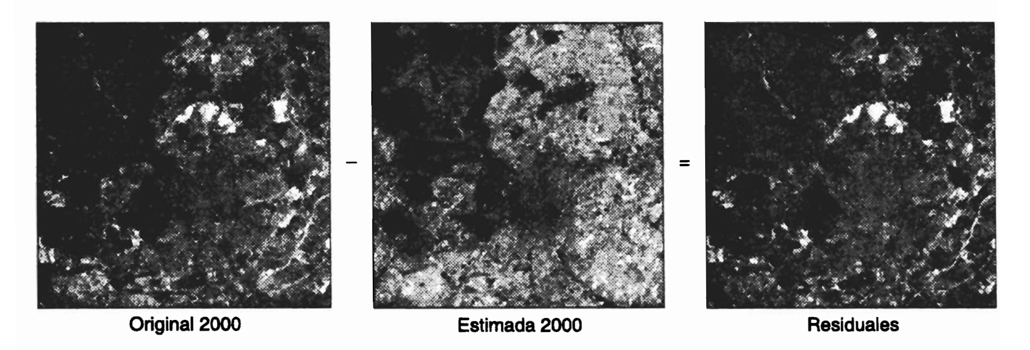


FIG. 7.66. *Regresión multitemporal de la imagen de Torrelaguna: (a) banda TM2 1992; (b) banda ETM2 2000; (c) imagen de residuales. Se señalan con círculos los cambios más evidentes.*

han ocurrido en esta ciudad a lo largo de la última década, principalmente la ampliación del aeropuerto de Barajas (al NE), la urbanización de los sectores comprendidos entre la M-30 y la M-40 al norte de la ciudad y la construcción de la M-45 y la línea de alta velocidad Madrid-Barcelona, ambos al este de la ciudad.

En el caso de la imagen de Torrelaguna, la regresión entre la banda 2 de las dos fechas facilitó un coeficiente de determinación (r^2) de 63,38 % con la siguiente regresión:

$$ND_{t2} = 13{,}436 + 0{,}584 \cdot ND_{t1}$$

Esta función se ha aplicado para obtener la imagen estimada de la segunda fecha (en este caso de 2000), que se ha restado de la imagen original para obtener los residuales. Esta imagen de residuales nos informa de los principales cambios producidos, tanto en su intensidad (valor), como su sentido (signo). Se observan nuevas áreas residenciales, al este, norte y centro de la imagen, así como la pérdida de buena parte del área embalsada en el Vellón.

La fig. 7.66 recoge la aplicación de la misma técnica a la misma ventana de la imagen Torre100 que hemos analizado a través del ACP. De nuevo se observa en la imagen de residuales los cambios más destacados entre fechas: alteraciones del nivel del agua, crecimiento urbano de Guadalix y apertura de nuevas urbanizaciones.

3.4.6. *Vectores multitemporales*

Es una técnica que intenta incorporar no sólo la importancia, sino también la dirección del cambio entre imágenes. Si representamos en un eje bivariado dos bandas originales (por ejemplo, rojo e infrarrojo cercano), cada píxel viene definido por un punto (localización de sus ND en las dos bandas). Si ese píxel cambia su cobertura entre dos fechas, también modificará su emplazamiento espectral. La magnitud del cambio vendrá dado por la longitud del vector que separa ambos puntos. Por su parte, el sentido del cambio se define por el ángulo que forma con el eje de referencia (fig. 7.67). Caso de que el píxel haya reducido el vigor vegetal, tenderá a disminuir su ND en el infrarrojo cercano y aumentarlo en el rojo. En consecuencia, el

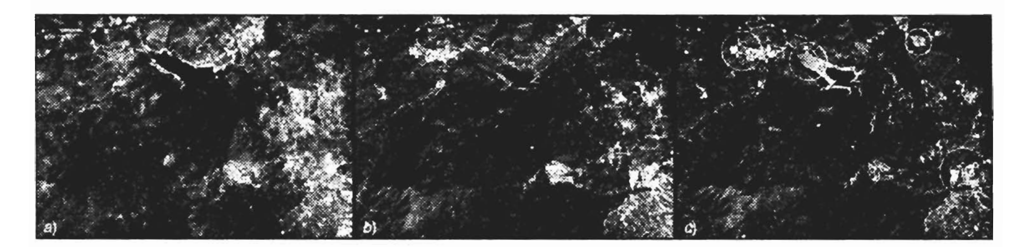


FIG. 7.67. *Ejemplo de vectores de cambio entre dos fechas de referencia.*

vector presentará una dirección descendente y hacia la derecha del gráfico (en términos geográficos tendría dirección SE). Por el contrario, si aumentara su cobertura vegetal el vector presentaría una dirección NW.

Con este sencillo ejemplo, podemos introducir el interés de este tipo de análisis para la detección de cambios, ya que nos ofrece una imagen de su magnitud y sentido. La intensidad del cambio se identifica con la longitud del eje, que puede obtenerse a partir de calcular la distancia entre la localización espectral de cada píxel en las dos fechas (fig. 7.68):

$$d_{i,j,c} = \sqrt{(\mathrm{ND}_{i,t1} - \mathrm{ND}_{i,t2})^2 + (\mathrm{ND}_{j,t1} - \mathrm{ND}_{j,t2})^2} \qquad \{7.59\}$$

donde $d_{i,j,c}$ indica la intensidad del cambio espectral en las bandas i, j entre los dos períodos considerados ($t1$ y $t2$). Por su parte, la dirección del cambio puede calcularse a partir del ángulo que forma el vector de cambio con la vertical (α):

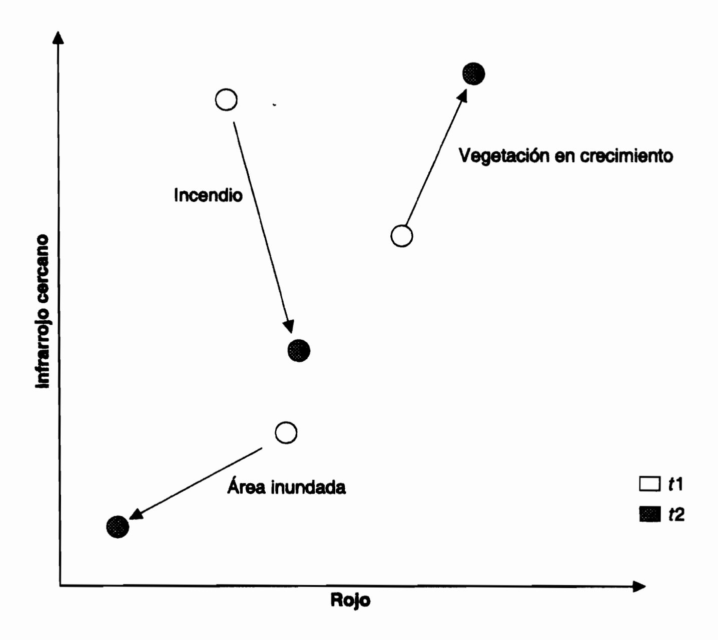


FIG. 7.68. *Vectores multitemporales para la detección de incendios (Buñol).*

$$\alpha = \text{arctg}\left(\frac{ND_{j,t1} - ND_{j,t2}}{ND_{i,t1} - ND_{i,t2})}\right) \qquad \{7.60\}$$

Esta técnica de comparación temporal se ha empleado bastante en los últimos años en el marco de la determinación de cambios con el sensor MODIS, que incluye un producto estándar basado en este enfoque (Zhan *et al.*, 2002).

En la figura 7.68 aparecen los dos componentes de intensidad y dirección del cambio para la imagen del incendio de Buñol. La imagen de intensidad muestra los tonos más claros para las áreas afectadas por el fuego, ya que son éstas las que han experimentado un cambio más intenso entre las dos fechas. Además se muestran en el vértice NE de la imagen unas pequeñas zonas afectadas por nubes en la segunda fecha, por lo que también ofrecen un cambio bastante intenso y, en consecuencia, tonos claros. La imagen inferior muestra la dirección del cambio. Como puede observarse las dos clases que más intensamente han cambiado (de vegetación sana a quemada, y de vegetación a nubes), muestran ahora tonos muy distintos, en función del sentido del cambio. En el primer caso, los tonos son oscuros, indicando que los ND de la segunda fecha son inferiores a los de la primera.

3.4.7. *El problema de delimitar los umbrales*

Todos los métodos hasta aquí analizados facilitan imágenes «continuas» del cambio. En otras palabras, el resultado de los cálculos es una imagen en donde el ND indica el grado de cambio, desde la mayor pérdida a la mayor ganancia, en una escala gradual. Habitualmente, el intérprete pretende más bien generar una imagen categorizada, en donde se separen las clases de cambio y no cambio. En consecuencia, es preciso segmentar la imagen resultante de las técnicas anteriores, de tal forma que se delimiten las zonas dinámicas de las que han permanecido estables. El límite entre ambas resulta complicado de trazar, ya que no contamos con criterios objetivos y de aplicación general. En teoría, el histograma de la imagen de cambios debería permitir esta segmentación, ofreciendo un perfil bimodal correspondiente a los píxeles estables y dinámicos.

Sin embargo, en la práctica, los histogramas no definen con tanta claridad ese umbral, ya que los cambios en la naturaleza no se producen de modo abrupto sino gradual, como ocurre con la imagen de cambios de Torrelaguna (fig. 7.69). En consecuencia, es preciso arbitrar algún criterio sólido que permita segmentar esa imagen de cambios en dos (p. ej., cambios / no cambios), tres (p. ej., incremento / estable / decremento), o más categorías (p. ej., alto incremento / moderado incremento / estable / moderado decremento / alto decremento).

Se han propuesto distintas opciones para establecer esos umbrales, ninguna de ellas plenamente satisfactoria y objetiva. Con frecuencia se han utilizado criterios estadísticos, basados en la media y algún múltiplo de la desviación típica, o la propia distribución del histograma (Hervás y Rosin, 2001). Lógicamente, el problema en ese caso sería fijar qué múltiplo es más apropiado, ya que no se conoce qué porcentaje de cambio incluyen las imágenes y por tanto no sabemos las unidades tipificadas que le corresponden. Algunos autores han ensayado la aplicación sucesiva

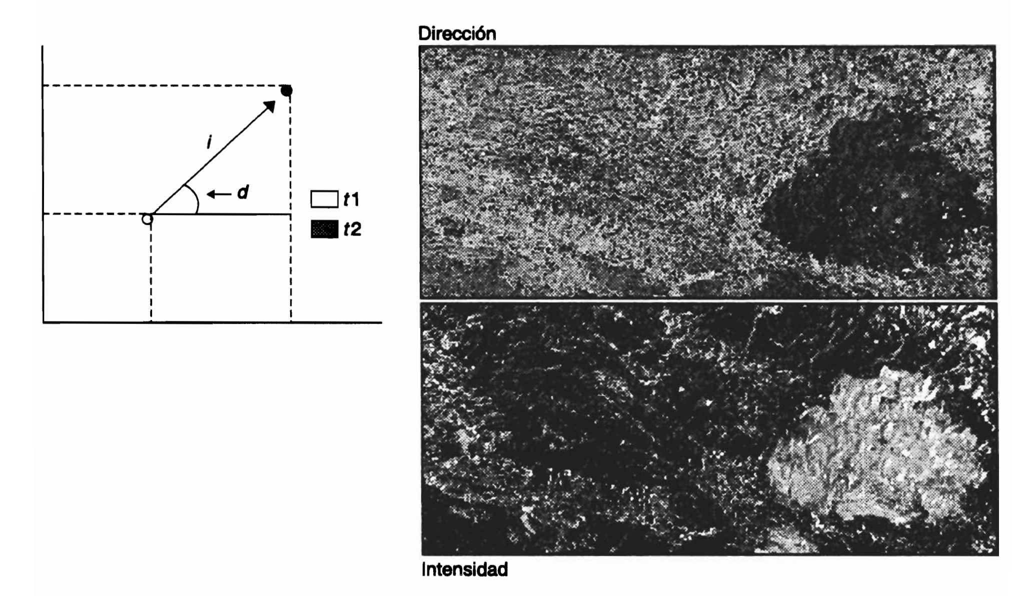


FIG. 7.69. *Histograma de la imagen de diferencias multitemporales de Torrelaguna.*

de distintos múltiplos de la desviación típica para delimitar cambios urbanos entre dos imágenes. En cada iteración, las zonas de cambio y no cambio se separaban a partir del límite fijado por *n* desviaciones típicas (± la media), variando *n* desde 0,1 hasta 2. Las áreas categorizadas como de cambio se verificaban con parcelas delimitadas en el terreno, calculándose la fiabilidad para cada iteración hasta encontrar el valor óptimo (Fung, 1992; Fung y LeDrew, 1988). Los límites idóneos variaban con cada técnica de detección utilizada, si bien se encontraban en torno a una desviación típica de la media. Ese límite puede considerarse estadísticamente razonable, pero no sabemos si el resultado es extrapolable a otra zona o a otro tipo de aplicación.

Más recientemente, se ha propuesto ajustar los umbrales de cambio considerando la función señal/ruido de un determinado sensor. Ese ruido puede provenir del incorrecto ajuste entre fechas, o de la propia radiometría del sensor. Se propone estimarlo a partir de una biblioteca de imágenes históricas de cambio, que permitan delimitar los umbrales de evidencia más apropiados para ese tipo de imágenes. Para un estudio de cambios urbanos con imágenes SPOT-P, los autores utilizan una biblioteca con 711 pares de cambios, extraídos de imágenes del mismo sensor para distintas zonas y fechas (Smits y Annoni, 2000).

Un segundo criterio parte de señalar umbrales de cambio a partir de valores críticos de incremento o decremento de una determinada variable física. Por ejemplo, puede dictaminarse que una disminución de temperatura superior a 10 °C entre dos imágenes tomadas en días consecutivos indicaría la presencia de nubes en la segunda imagen, o que un decremento mayor de un cierto umbral de NDVI manifiesta un cambio abrupto en la vegetación que sólo puede deberse a un tránsito de vegetación a suelo. Éste ha sido de hecho un criterio habitual para delimitar áreas quemadas a partir de imágenes TM y AVHRR (Martín y Chuvieco, 1995). El valor específico de

esos umbrales puede derivarse a partir de medidas de laboratorio tomadas con espectro-radiómetro.

También puede optarse por señalar umbrales de cambio adaptados al entorno, aplicando técnicas de contexto espacial, que antes comentamos. Por ejemplo, pueden determinarse como cambios aquellos píxeles que superen un cierto umbral de desviaciones típicas sobre el cambio observado en una ventana que les circunde.

Finalmente, se pueden seleccionar los umbrales de cambio a partir de una clasificación de las imágenes de cambio obtenidas con distintas técnicas, con objeto de establecer grupos homogéneos de píxeles estables y dinámicos. Pueden realizarse clasificaciones supervisadas, a partir de áreas que se conozcan como estables o dinámicas, o no supervisadas, dejando al programa que seleccione los grupos naturales presentes en esas imágenes. El criterio ha dado buenos resultados en aplicaciones forestales (Coppin y Bauer, 1994) —clasificando imágenes de cambio generadas a partir de la transformación *tasseled cap*, índices de vegetación y análisis de componentes principales—, y urbanas (Wang, 1993), en este caso sobre las bandas originales de las dos fechas.

Sea uno u otro el criterio que se utilice, conviene recordar que la mayor o menor rigidez de los umbrales implicará incrementar o disminuir los errores de omisión, o inversamente los de comisión, por lo que el usuario tendrá que decidir en primer lugar qué tipo de error resulta más tolerable. Volviendo al ejemplo de la delimitación de áreas quemadas, los umbrales muy exigentes reducirían las áreas no quemadas que se discriminen como tales, a la vez que aumentarían los píxeles realmente quemados que no se detectarían con ese algoritmo (fig. 7.70). En este caso concreto, pensamos que resulta más adecuado optar por la segunda opción, de cara a reducir los errores de comisión, y aplicar posteriormente un algoritmo de contexto para delimitar con mayor nitidez las áreas realmente quemadas. Otro aspecto interesante en la delimitación de umbrales es el carácter fragmentario que puede tener la imagen resultante, ya que los límites se establecen por cortes en el histograma de cambios y no por criterios espaciales. Para solventar este problema puede resultar conveniente aplicar algún filtro modal a las imágenes resultantes (fig. 7.71) o eliminar aquellos grupos de píxeles que sean más pequeños de un determinado tamaño (Fernández-Gustiz, 2001). Esto es una práctica frecuente cuando se pretende delimitar una única categoría objetivo, como sería el caso de las máscaras de nubes o la caracterización de áreas quemadas (Chuvieco *et al.*, 2008; Chuvieco *et al.*, 2008).

3.4.8. *Análisis multitemporal de imágenes clasificadas*

La detección de cambios puede también abordarse empleando las técnicas de clasificación antes comentadas. En este caso, no se presenta el problema de delimitar umbrales, ya que clasificar lleva consigo discretizar la escala continua de las imágenes originales, por tanto comparaciones multitemporales se realizan entre categorías.

La detección de cambios a partir de técnicas de clasificación puede abordarse empleando dos grupos de técnicas: 1) por un lado, comparar imágenes previamente clasificadas, y 2) por otro, clasificar conjuntamente las imágenes de las dos fechas.

En el primer caso, se aborda una clasificación para cada imagen por separado,

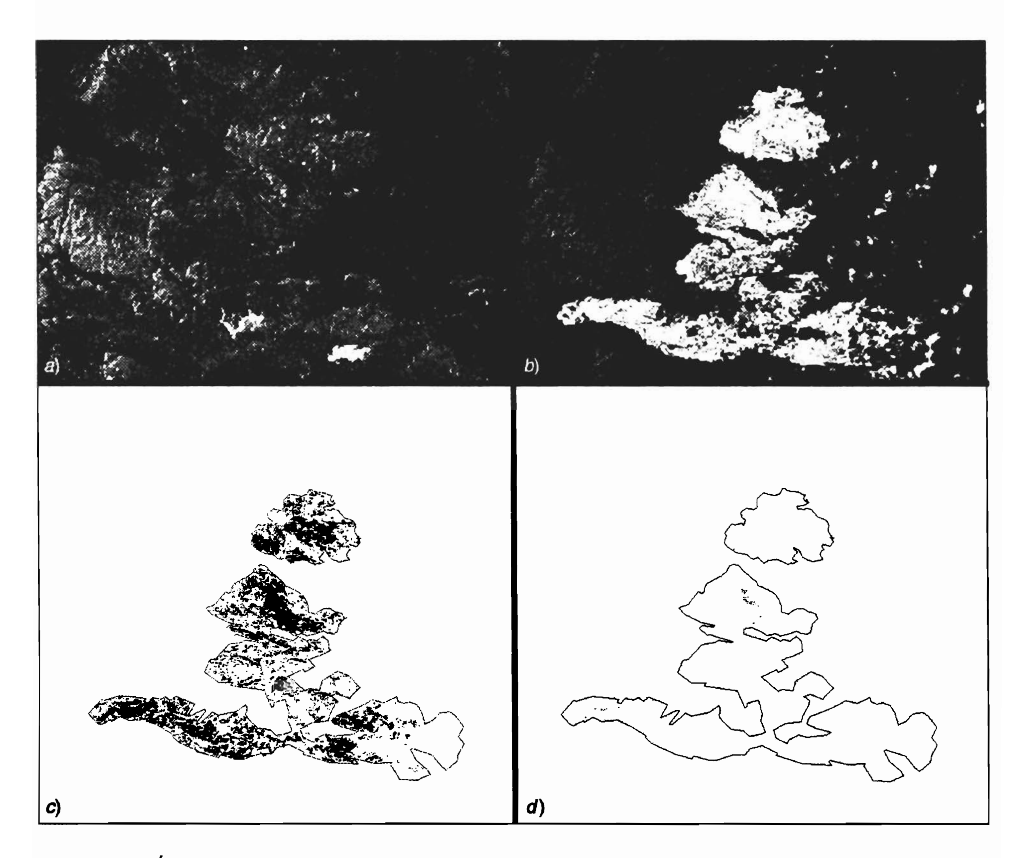


FIG. 7.70. *Índice de área quemada para la imagen de Buñol, antes (*a*) y después del incendio (*b*). Aplicación de umbrales laxos (*c*) y estrictos (*d*) para discriminar área quemada.*

cuidando de emplear la misma leyenda temática en las dos fechas, con objeto de que puedan compararse posteriormente. A continuación, se genera una tabla multitemporal de cambios, en donde se presentan las transiciones que se producen entre las dos fechas (tabla 7.16). En la diagonal de esta tabla aparecen los píxeles estables (que cuentan con la misma categoría en las dos fechas), mientras los cambios se detectan en el resto de las celdillas. El gran interés de esta tabla es ofrecernos las transiciones que se han producido. En otras palabras, no sólo observamos las zonas estables y dinámicas, sino también cuál era la cobertura original y cuál la actual, lo que nos indica las tendencias del cambio en la zona de estudio. En un estudio de deforestación, esto nos permitiría conocer qué tipo de especies forestales están siendo más afectadas; en una evaluación de incendios, qué especies se han quemado, o en un estudio urbano, qué espacios están experimentado un mayor proceso de urbanización (Adeniyi, 1985; Coppin y Bauer, 1994; Howarth y Boasson, 1983; Jakubauskas *et al.*, 1990; Molina y Chuvieco, 1997). Es interesante considerar que esta matriz es cuadrada pero no simétrica, ya que indica cambios que pueden ser contrarios («de cultivo a bosque», frente a «de bosque a cultivo»). Por ello, el análisis de las celdas resulta de interés por encima de los totales de cada categoría, ya que los valores absolutos

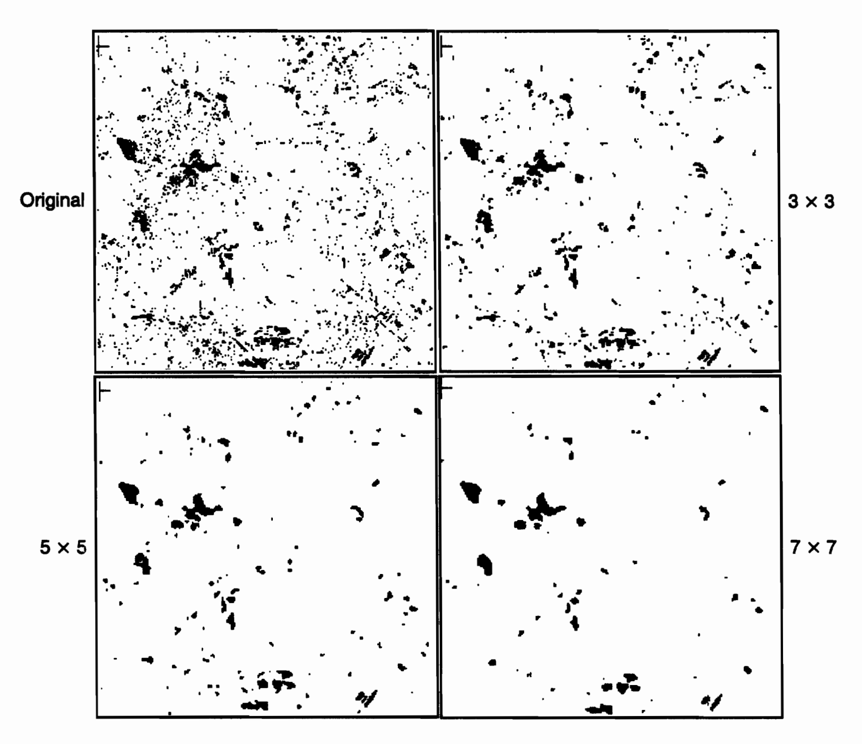


FIG. 7.71. *El empleo de filtros modales restringe las áreas de cambio detectadas entre imágenes (Fernández, 2001).*

TABLA 7.16. *Cambios urbanos en la ciudad de Madrid a través del análisis de dos imágenes Landsat-TM y ETM (en hectáreas)*

		1992						
		Vegetación	*Matorral-pastizal*	*Secano**	*Suelos*	*Áreas urbanas*	*Agua*	*Total*
2000	*Vegetación*	10.775,38	4.681,44	666,31	77,81	1.669,19	14,13	17.884,25
	Matorral-pastizal	793,31	5.188,75	5.924,94	346,38	1.605,44	5,50	13.864,31
	Secano	468,63	2.566,81	2.507,44	130,50	456,88	1,25	6.131,50
	Suelos	134,63	1.182,69	3.992,75	816,06	950,94	1,00	7.078,06
	Áreas urbanas	1.209,56	1.778,81	2.034,63	603,13	7.475,31	3,13	13.104,56
	Agua	60,50	9,00	9,50	5,31	19,81	151,44	255,56
	TOTAL	13.424,00	15.407,50	15.135,56	1.979,19	12.177,56	176,44	58.318,25

* La imagen de 2000 se tomó en primavera, de ahí algunos cambios en esta categoría entre las dos fechas: (Fernández, 2001).

de cambio pueden esconder mezclas entre cambios contrarios (Pontius *et al.*, 2004). Por ejemplo, si en una determinada zona se pasa de 140,000 has forestales a 120,000, la conclusión inicial sería que se han perdido 20,000 has, pero en realidad pueden haberse deforestado muchas más, compensando esa pérdida con la regeneración de otras.

A partir de la matriz de cambios puede calcularse algún estadístico que mida el grado de cambio entre las dos fechas, considerando el grado de asociación entre las filas y las columnas. Por ejemplo, el índice Kappa —que permite calcular el grado de acuerdo entre filas y columnas de una matriz cuadrada, como luego veremos en el contexto de la verificación de imágenes (cap. 8)—, permite medir también el grado de cambio entre las dos fechas: cuanto más alto sea el valor, indicaría una mayor estabilidad.

En un análisis posterior podría analizarse el origen de estos cambios, acudiendo a información auxiliar almacenada en un SIG. Por ejemplo, abandonos de tierras podrían explicarse por factores relacionados con la productividad del suelo, con la topografía o con la accesibilidad.

El principal problema de esta tabla es su gran dependencia de la fiabilidad de las clasificaciones individuales. En otras palabras, si las clases no se han discriminado correctamente en cualquiera de las dos fechas, los cruces entre categorías resultarán erróneos, ofreciendo una información imprecisa del cambio. En cualquier caso, la fiabilidad de la tabla multitemporal siempre es inferior a las fiabilidades de cada clasificación.[3] El empleo de técnicas de clasificación borrosa puede paliar algunos de estos errores, ya que ciertas transiciones imposibles (p. ej., de urbano a rural) pueden solventarse observando el grado de pertenencia de cada píxel a esas categorías en las dos fechas (Wang, 1993). Este enfoque «borroso» en el análisis temporal resulta especialmente útil cuando pretendemos analizar la dinámica de un fenómeno que presenta una distribución gradual en el espacio, como podría ser la densidad y estado de la vegetación (Foody, 2001).

Otro aspecto a considerar en la comparación entre clasificaciones afecta a la cartografía de resultados. Puesto que podemos encontrar cruces múltiples entre las categorías de las dos fechas, el número de clases a cartografiar puede ser bastante elevado. Por ejemplo, con una sencilla clasificación de 8 categorías por fecha, tendríamos 64 clases resultantes posibles. Aunque puede haber algunas de ellas que estén vacías (ya que hay cruces temporales prácticamente imposibles), la representación gráfica de esas concurrencias resulta bastante complicada. Una alternativa para representarlos sería recoger varios mapas del mismo cruce, por ejemplo uno por categoría de la segunda fecha, indicando con tramas o colores su origen en la primera fecha. Esto es lo que se presenta en la figura 7.72, que recoge la dinámica de dos categorías en la imagen Torre100. Los tonos blancos indican zonas estables y los de gris señalan cuál es la cobertura de la primera fecha. Gracias a esto, pueden observarse tanto las áreas estables como las transiciones que se han producido entre las dos imágenes.

El otro enfoque de la clasificación multitemporal considera la asignación conjunta de las dos fechas. En este caso, la clasificación resultante estará formada por cate-

3, Concretamente es su producto. Si las clasificaciones individuales cuentan con una exactitud de 0,85 y 0,90, la fiabilidad de la multitemporal será de $0,85 \times 0,90 = 0,76$.

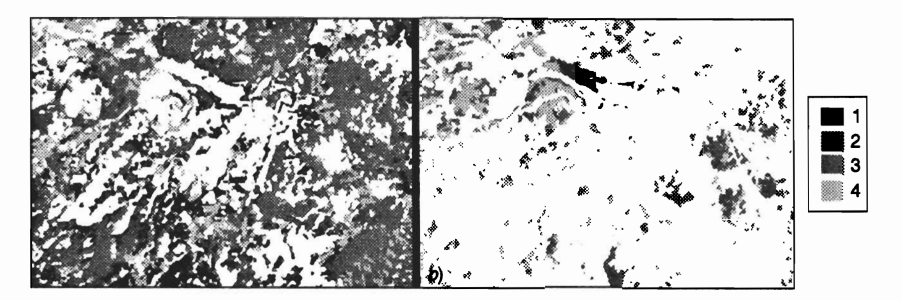


FIG. 7.72. *Cartografía dinámica sobre una ventana de la imagen de Torrelaguna (1984-2000): (a) procedencia del suelo; (b) procedencia del pastizal. En ambos casos el 1 indica agua; el 2 matorral; el 3 pastizal y el 4 suelo descubierto. En blanco, se señalan las zonas estables.*

gorías multitemporales, definidas por su estabilidad o por su cambio entre las dos imágenes que se consideren. Nombres apropiados a estas clases podrían ser, por ejemplo, «transición de zonas rurales a urbanas», «cambios de agricultura de secano a regadío», o «urbano estable». Esas clases pueden deducirse de una clasificación supervisada, en donde el intérprete señale como áreas de entrenamiento aquellos sectores que hayan experimentado las transformaciones más interesantes. La leyenda de trabajo, por tanto, tendría que ser dinámica, incluyendo categorías de estabilidad y de cambio (por ejemplo, áreas que eran rurales en la primera fecha y pasaron a urbanas en la segunda, o zonas de cultivo estable). También puede optarse por la clasificación no supervisada, donde el algoritmo de agrupación identificará los grupos de estabilidad y cambio más importantes de la imagen, quedando luego al intérprete la tarea de asignar esos grupos a categorías multitemporales significativas. En este caso, la fiabilidad de la comparación temporal no depende de la obtenida en cada imagen, sino que se mide sobre la clasificación resultante, ya que las dos fechas se agrupan conjuntamente. Algunos trabajos recientes señalan el interés de realizar estas comparaciones temporales no supervisadas incluyendo explícitamente el componente textural, de cara a obtener productos más robustos espacialmente (Bruzzone y Fernández-Prieto, 2000).

4. Determinación de la estructura espacial del territorio: la imagen como mosaico paisajístico

4.1. TELEDETECCIÓN Y ECOLOGÍA DEL PAISAJE

Frente a la óptica tradicional de la ecología de campo, preocupada por los análisis a escala de detalle, ha crecido en los últimos años el interés por extender estas observaciones a un marco más amplio, de tal forma que se incluya explícitamente la variación espacial en el análisis y gestión integral de ecosistemas. En este enfoque, la teledetección y los SIG pueden jugar un papel muy destacado, ya que son técnicas que permiten gestionar información georreferenciada, facilitando el análisis espacial de los datos, así como la obtención de variables críticas para un entendimiento más completo del medioambiente (Hoffer, 1994; Wilkie y Finn, 1996).

Hemos visto en anteriores capítulos que el análisis de imágenes de satélite pro-

porciona la distribución espacial de algunas variables que son claves para entender el funcionamiento de un ecosistema, como son la temperatura de superficie, la radiación interceptada por la vegetación, el contenido de clorofila o de agua en las hojas, o el índice de área foliar.

En este capítulo, vamos a centrarnos en los métodos para obtener información sobre las relaciones espaciales entre los elementos que forman la imagen. Una imagen de satélite puede considerarse como una representación digital del mosaico que forma un determinado paisaje. Por tanto, a partir de estas imágenes pueden medirse las relaciones espaciales entre los elementos de ese mosaico, denominados, en ecología del paisaje, manchas o teselas *(patches)*. Al tratarse de una imagen digital, pueden aplicarse sobre las bandas originales, sobre alguna transformación de ellas o sobre una imagen ya clasificada, medidas que permitan evaluar cómo se configuran las distintas cubiertas en un territorio concreto.

El patrón espacial con el que se presentan las diversas coberturas terrestres tiene gran interés para entender ciertos procesos ecológicos, como la dispersión de organismos, el uso de los recursos por parte de la fauna local (Congalton *et al.*, 1993), la comunicación genética o la extensión espacial de ciertas alteraciones, como son las causadas por fuegos o plagas (Hargrove *et al.*, 2000; Muchoki, 1988; Sample, 1994), además de estar directamente relacionada con la biodiversidad (Roy y Tomar, 2000). Por ejemplo, la fragmentación espacial del paisaje, que está relacionada con la conectividad / aislamiento que presentan las distintas manchas, puede dificultar la migración de especies, lo que implica un deterioro, o incluso una desaparición de las mismas, al degradarse su composición genética (Griffiths *et al.*, 1993). De igual modo, la proximidad a carreteras o áreas agrícolas está relacionada con situaciones de desequilibrio, pues implica una alteración del número y/o tipo de especies que aparecen en esos bordes. Obviamente, esto no es aplicable por igual a cualquier especie, por lo que es preciso reforzar la investigación sobre las relaciones entre estructura espacial y funcionamiento de los ecosistemas. En consecuencia, la gestión integrada de los mismos implica contar con información no sólo sobre el tipo de cubiertas presentes en el territorio, sino también sobre su disposición espacial. La reciente tendencia a asegurar un «medioambiente sostenible», implica considerar varios aspectos, como son minimizar la fragmentación del hábitat, mantener la biodiversidad, identificar y gestionar efectos acumulativos, y analizar, predecir y vigilar impactos a varias escalas espaciales y temporales (Green, 1994; Haines-Young *et al.*, 1993; Quattrochi y Goodchild, 1997; Saura, 2002; Wilkie y Finn, 1996).

El empleo de imágenes de satélite en ecología del paisaje tiene una historia reciente, pero ya cuenta con interesantes ejemplos (Frohn, 1998; Gulinck *et al.*, 1991). En este campo la teledetección ofrece una visión sinóptica del paisaje, constituye un conjunto homogéneo de medidas y facilita el seguimiento multitemporal de fenómenos que afectan a la composición del territorio (Delbaere y Gulinck, 1995). De acuerdo a Walsh *et al.* (1998), la teledetección ofrece en este ámbito de trabajo las siguientes ventajas:

1. Permite verificar la composición del paisaje para unidades espaciales de información (píxeles), unidades biofísicas (p. ej., cuencas) y para su agregación espacial.

2. Ofrece una representación espacial de la estructura del paisaje.
3. Facilita una análisis de la autocorrelación espacial de diversas variables paisajísticas, como la cobertura del territorio, la humedad del suelo, la geología superficial, a distintas escalas espaciales.
4. Permite calcular índices del patrón espacial de diversas variables paisajísticas de cara a mejorar la planificación espacial del territorio.

El análisis de la estructura espacial que contiene una imagen de satélite ha sido hasta hace unos años un tema mas o menos marginal, tal vez como consecuencia de la escasa resolución espacial que proporcionaban las imágenes. Temas como el reconocimiento automático de ciertas formas, sólo se están aplicando desde la disponibilidad de imágenes de muy alta resolución espacial. No obstante, los aspectos de variación espacial en las imágenes se han venido analizando desde los años ochenta, sobre todo orientados a entender mejor las relaciones entre resolución espacial y escala (Woodcock y Strahler, 1987; Woodcock *et al.*, 1988; Woodcock *et al.*, 1988), si bien son más numerosos los trabajos que utilizan la variación espacial para mejorar la discriminación de algunas cubiertas, como ya indicamos en nuestro comentario de los clasificadores de contexto (7.2.3.5). Respecto a los estudios de estructura espacial del territorio, los ejemplos no son muy abundantes (Vega-Garcia y Chuvieco, 2006). También aquí podríamos hacer una división entre aquellos trabajos que se basan sobre las imágenes medidas en escala continua, ya sean originales, ya aplicando alguna transformación aritmética (índices de vegetación o componentes principales, por ejemplo), y aquellos que se basan sobre imágenes clasificadas, esto es, medidas en escala nominal. Sobre estos dos grupos dividiremos la exposición.

4.2. Técnicas para medir la estructura espacial de una imagen

4.2.1. *Medidas de la variación espacial en imágenes de intervalo*

Hace referencia este término a imágenes en las que los ND están medidos en una escala numérica continua, por lo que pueden aplicarse sobre ellas técnicas estadísticas apropiadas a variables de intervalo. El objetivo de estas técnicas es medir la textura o contraste espacial entre los píxeles que componen la imagen. Si en términos de interpretación visual, la textura hace referencia a la diversidad espacial de los tonos de gris en una imagen, los índices numéricos de textura se dirigen a medir ese contraste en la vecindad de los ND de la imagen. Algunos de estos índices operan sobre toda la imagen y proporcionan una sola medida del contraste, mientras otros calculan la textura local, normalmente comparando el ND de un píxel con el de los que le circundan. Los primeros son útiles para comparar la complejidad espacial de distintas zonas, o para analizar la evolución en el tiempo de un determinado sector. En cuanto a los segundos, permiten generar imágenes de textura espacial, sirviendo también como variable auxiliar para la clasificación de categorías temáticas.

Entre los índices aplicables al conjunto de la imagen, podemos comentar los siguientes:

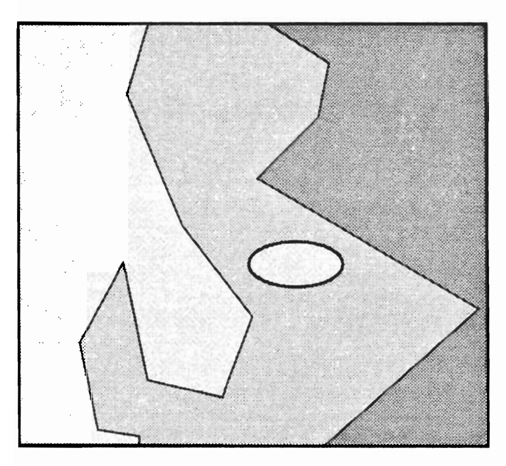
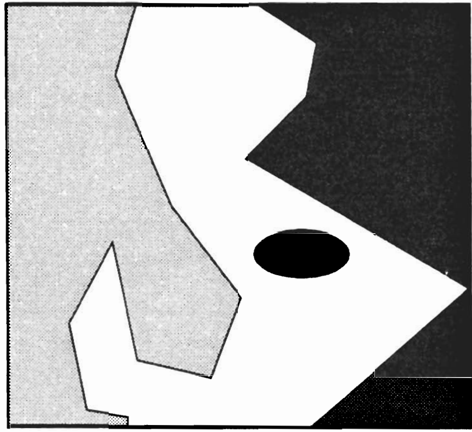



FIG. 7.73. *Ejemplo de dos imágenes con el mismo patrón espacial pero distinto contraste tonal.*

1. *Desviación típica (DT) a lo largo de perfiles.* La DT del conjunto de la imagen no resulta apropiada para medir el contraste espacial de la imagen, ya que no mide realmente el contraste espacial sino más bien el tonal (anchura del histograma). Dos imágenes pueden tener el mismo patrón espacial pero DT muy distintas, por contar con una cubierta que presente un marcado contraste espectral con el resto (fig. 7.73). Por esta razón, es preferible emplear la DT calculada para los ND de los píxeles que atraviesen uno o varios transectos de la imagen. En este caso, con algunas de las limitaciones antes apuntadas, la DT resulta más apropiada para ver el contraste espacial, pues informa sobre la variedad entre píxeles que están próximos. Imágenes que hayan perdido diversidad espacial, como consecuencia de cambios en la cobertura del suelo, tenderán a presentar un perfil más plano, con menor aparición de crestas y valles marcados (fig. 7.74).

2. *Dimensión fractal.* La geometría fractal asume que la dimensión de un objeto no es entera, sino real. En la geometría clásica, una línea posee una dimensión de 1, una superficie de 2 y un volumen de 3. En términos fractales, una línea posee una dimensión comprendida entre 1 y 2, con valores tanto más altos cuanto más complejo sea su trazado. En el contexto del análisis de imágenes, la dimensión fractal puede facilitar una valoración numérica del grado de complejidad espacial de una determinada escena. Al tratarse de una superficie, una imagen tendrá una dimensión fractal entre 2 y 3, aproximándose más a 3 cuanto mayor heterogeneidad espacial presente. Aunque esta medida se ha empleado en diversos estudios de ecología del paisaje, su cálculo no es muy evidente sobre una imagen de intervalo. En una aplicación pionera de la geometría fractal al análisis de imágenes Landsat, Lam (1990) midió la dimensión fractal de imágenes TM correspondientes a distintos paisajes. De acuerdo a lo esperable, el valor más alto calculado correspondió a una imagen de un área urbana, frente a otras con mayor predominio de espacios rurales. Las bandas más heterogéneas espacialmente resultaron la 1, 2 y 3, y la más homogénea la 6 (térmica), por contar con menor resolución espacial y radiométrica que las visibles. En todos los ejemplos, se encontró que la dimensión fractal de una imagen no clasificada es bastante alta, superando el valor 2,6 (salvo la térmica, con un va-

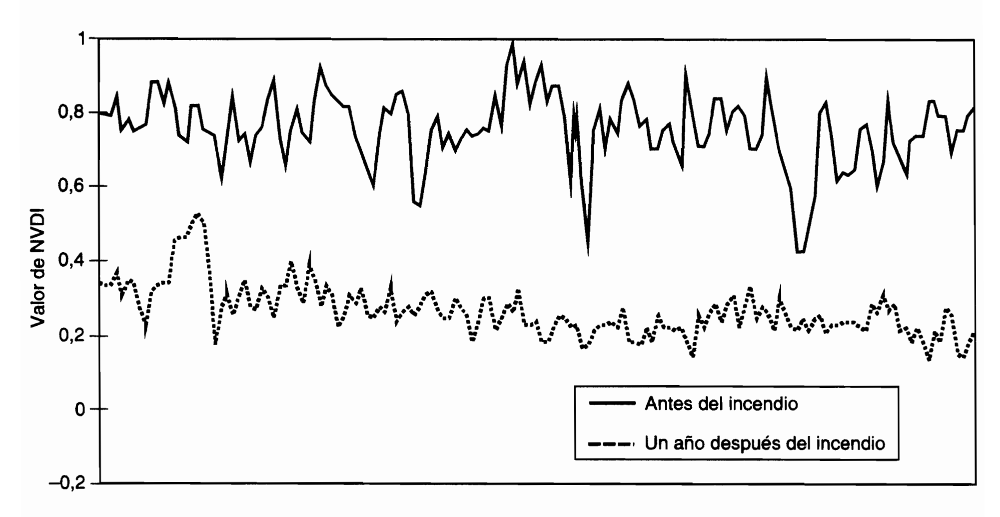


FIG. 7.74. *Cambio en el perfil de los valores de NDVI de una zona como consecuencia de un incendio (Chuvieco, 1999).*

lor de 2,2), lo que indica que las imágenes de satélite son espacialmente mucho más complejas que otras variables geográficas, como los MDE (Lam, 1990). Otros estudios han aprovechado estas medidas fractales para caracterizar la variación espacial de las alturas de los árboles, de cara al inventario forestal (Drake y Weishampel, 2000), y a analizar los patrones de regeneración post-incendio a partir de imágenes de NDVI (Ricotta *et al.*, 1998).

3. *Auto-correlación espacial (AE).* Las técnicas de AE pretenden medir la asociación entre variables debida a la distancia (Cliff y Ord, 1973). Resulta lógico pensar que los rasgos de la cubierta terrestre se parecen más entre sí cuanto más cerca están, ya que en el paisaje son poco comunes los cambios bruscos. La medida de esta asociación espacial puede obtenerse a partir del índice (I), ideado por Moran (1948), que mide la correlación que existe entre cada píxel y sus vecinos:

$$I = (n/2A) \cdot \left(\left(\sum_{i=1,v} \sum_{j=1,n} z_i z_j \right) / \sum_{i=1,n} z_i^2 \right) \qquad \{7.61\}$$

donde n indica el número de píxeles considerados, A el número de posibles uniones entre esos píxeles, z_i la desviación del píxel i frente a la media de la imagen ($ND_i - ND_x$), y z_j las desviaciones frente a la media de todos los píxeles adyacentes al píxel i. Al igual que el coeficiente de correlación de Pearson, el índice de Moran oscila entre –1 y +1, aumentando cuanto mayor sea la uniformidad espacial del paisaje. Puede calcularse para cualquier dirección (de modo similar al movimiento del rey sobre un tablero de ajedrez), o para algunas direcciones (caso del alfil o de la torre). Este índice se ha utilizado como medida de la uniformidad del paisaje, así como para estudiar los efectos que provocan distintos fenómenos exógenos (Congalton, 1988; Henebry, 1993; Pickup y Foran, 1987).

4. *Semi-variograma.* Basado sobre el mismo concepto de autocorrelación es-

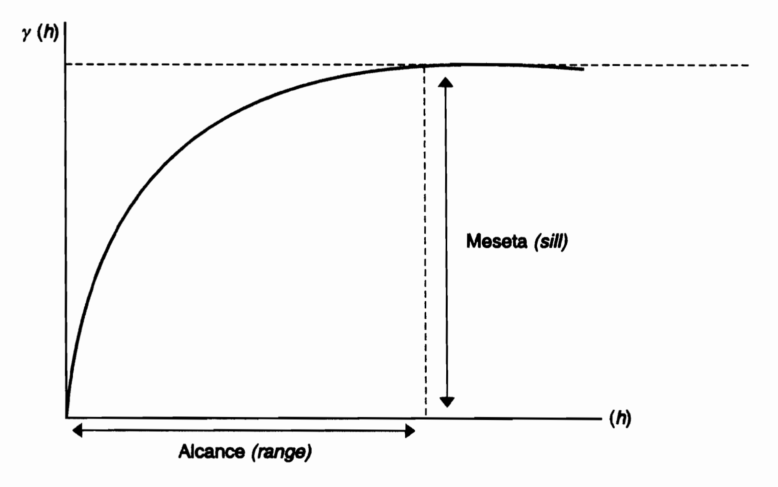


FIG. 7.75. *Representación gráfica de un semi-variograma.*

pacial, puede obtenerse un gráfico que muestre cómo se modifica la varianza espacial (esto es, la dispersión de un conjunto de valores vecinos) con la distancia, lo que permite tener una idea bastante precisa de la variación espacial de una imagen. El semi-variograma se obtiene a partir de la siguiente función (Chica, 1988):

$$\gamma(h) = \frac{1}{2NP(h)} \sum_{i=1,NP(h)} (\mathrm{ND}(x_i + h) - \mathrm{ND}(x_i))^2 \qquad \{7.62\}$$

donde $\gamma(h)$ indica la varianza espacial para una distancia h, $NP(h)$ el número de píxeles incluidos en ese radio h, y ND (x_i) el ND correspondiente al píxel x_i. El semi-variograma se puede calcular en una dirección determinada o, lo que es más habitual en teledetección, en un radio, considerando todas las direcciones. La representación gráfica de $\gamma(h)$ nos muestra cómo aumenta la varianza en función de la distancia (fig. 7.75). Inicialmente la curva tiende a un trazado ascendente, ya que al considerar píxeles cada vez más alejados la varianza aumenta. Sin embargo llega un momento en que se estabiliza, de tal forma que al incrementarse el radio de cálculo no aumenta la varianza significativamente. Esa distancia crítica se denomina alcance *(range)*, y el valor al que se estabiliza la varianza, meseta *(sill)*. Alcance y meseta son de gran interés para entender la estructura espacial de una imagen. Cuanto mayor contraste espacial presente, tanto el rango como la meseta tenderán a ser mayores. La proporción en la que varía una y otra depende de la disposición del mosaico paisajístico de la imagen.

En un trabajo de gran interés sobre discriminación de morfología forestal, se calculó el semi-variograma para varias imágenes obtenidas por videografía (con resolución de 1 m) sobre diversas plantaciones de coníferas (Cohen *et al.*, 1990). Los autores del estudio observaron que el alcance estaba directamente relacionado con la anchura de la copa —siendo mayor para las parcelas con árboles añejos, muy desarrollados—, mientras la meseta hacía referencia a la estratificación del dosel vegetal. Conviene considerar que estas observaciones dependen directamente de la

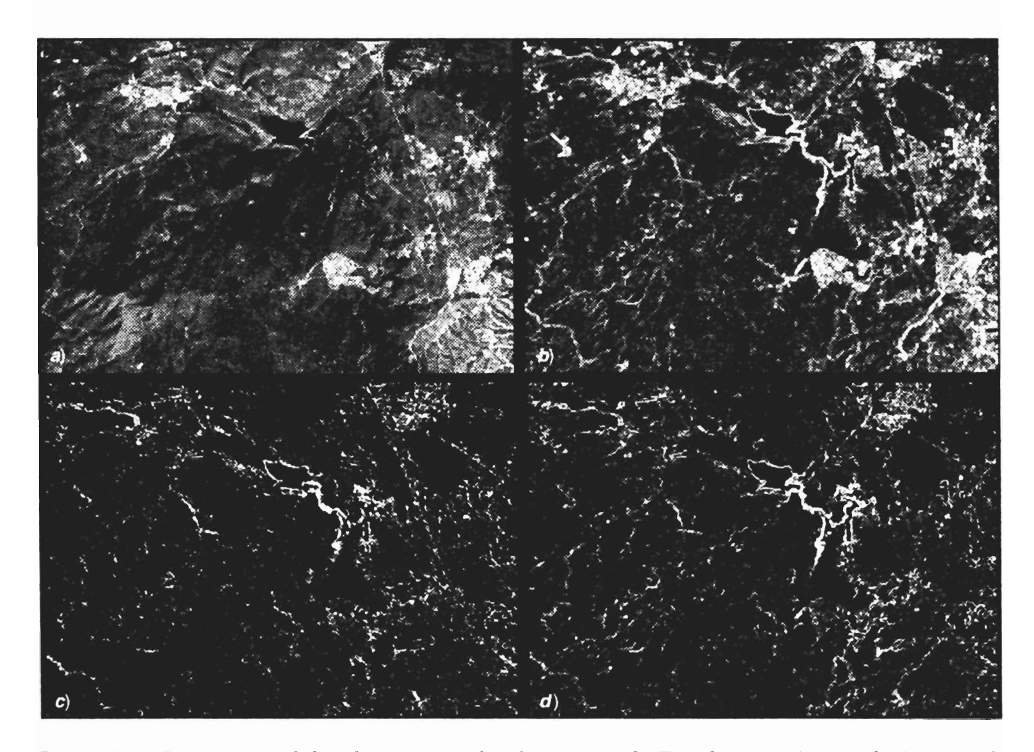


FIG. 7.76. *Diversas medidas de textura sobre la imagen de Torrelaguna:* (a) *Banda 2 original;* (b) *Desviación típica local;* (c) *Contraste sobre la matriz de concurrencia, dirección vertical;* (d) *Idem, dirección promedio.*

resolución de la imagen y, más en concreto, de la relación entre el tamaño de los objetos que se estudian (en este caso, la anchura de las copas) y el tamaño del píxel. De hecho, estos autores comprobaron cómo las imágenes de vídeo reducían notablemente su capacidad para discriminar rasgos espaciales al degradarse a 10 m, mientras no permitían deducir una relación significativa entre semi-variogramas y características del dosel forestal al degradarse a la resolución del Landsat-TM (Cohen *et al.*, 1990). En este sentido, el semi-variograma se ha comprobado que resulta de gran interés para describir las relaciones entre el tamaño de los objetos y la resolución espacial del sensor, encontrándose que el máximo de varianza local se produce entre fi y fl del tamaño medio de los objetos (Woodcock y Strahler, 1987; Woodcock *et al.*, 1988).

En consecuencia, el semi-variograma también ayuda a seleccionar la resolución óptima para abordar un determinado estudio, facilita el diseño de redes de medida *in situ* y de campañas de muestreo, al proporcionarnos una imagen de la distancia máxima a la cual los ND de la imagen se parecen excesivamente entre sí (Caselles, 1987). Se ha utilizado con éxito para analizar la estructura espacial de la vegetación, de cara a diferenciar el impacto territorial en una determinada perturbación (Viedma *et al.*, 1999). Asimismo, como luego veremos (cap. 8), puede aplicarse al estudio de la estructura espacial de los errores, ya sean debidos a la clasificación temática (Congalton, 1988), ya al registro geométrico (Dai y Khorram, 1998).

Además de estos índices que facilitan una evaluación global de la textura de la imagen, también podemos comentar otros métodos que permiten generar imágenes de textura, analizando la heterogeneidad espacial en las inmediaciones de cada píxel. Normalmente, estas técnicas se basan en ventanas móviles, más o menos grandes dependiendo de la distancia de la vecindad que consideremos. A partir de ellas, se calcula la textura en torno al píxel central que se evalúe en cada momento, de modo similar a las operaciones de filtraje previamente vistas (6.5.4). Conviene insistir en que estas nuevas bandas de textura pueden utilizarse como entrada en la clasificación digital, facilitando la discriminación de algunas cubiertas que pueden ofrecer valores espectrales similares, pero espaciales muy diferenciados. Este enfoque puede resultar especialmente útil para discriminar rasgos urbanos, que cuentan con mayor heterogeneidad espacial que cualquier otra cubierta (Molina y Chuvieco, 1996; Smits y Annoni, 1999), pero también se ha mostrado de gran interés en la cartografía de la vegetación, especialmente cuando resulta necesario extraer información sobre sus características estructurales (Salas, 1995, #1371; Riaño, 2001, #3313; Yool, 1985, #576). Entre las técnicas más utilizadas para generar imágenes de textura podemos citar las siguientes:

5. *Desviación típica local.* Se calcula como la dispersión de los ND de una ventana de píxeles en relación con su promedio. Esta medida resulta muy sencilla y se ha comprobado eficaz en el inventario forestal, como indicador de la densidad y homogeneidad de especies, lográndose significativas mejoras frente a clasificaciones sólo espectrales (Strahler, 1978, #1672; Strahler, 1984, #519). Como puede observarse en la figura 7.77*b*, en una ventana de la imagen Torrel00 próxima al embalse del Vellón, esta medida de textura facilita valores más altos para las zonas más contrastadas espacialmente, pudiendo delimitar con cierta claridad los núcleos urbanos y áreas residenciales de las superficies vegetales.

6. Diferencias absolutas entre los ND máximos y mínimos de la ventana considerada:

$$Y = \left| \mathrm{ND}_{\max,i} - \mathrm{ND}_{\min,i} \right| \qquad \{7.63\}$$

siendo i cualquiera de los píxeles adyacentes al central de la ventana. Este sencilla medida se ha empleado para estimar la textura en zonas de praderas afectadas por distintos procesos ambientales (Briggs y Nellis, 1991). Gracias también a estas medidas de textura ha sido posible discriminar entre frutales de regadío y caducifolias, empleando las bandas TM3 y TM4 (Gordon y Philipson, 1986).

7. *Entropía.* Se define como la relación entre la frecuencia de un determinado ND (F_{Ndi}) y la frecuencia máxima esperable en la ventana de píxeles considerada:

$$\mathrm{Ent} = \sum_{i=0,p} \frac{F_{\mathrm{ND}i}}{n} \ln \frac{F_{\mathrm{ND}i}}{n} \qquad \{7.64\}$$

donde p el rango de ND en la imagen (256 para una imagen de 8 bits) y n el número de píxeles en la ventana. Esta medida se ha utilizado en la clasificación de áreas urbanas (Gong *et al.*, 1992).

4	6	8	5	4
5	5	8	7	6
6	7	7	7	9
8	8	4	8	6
9	8	9	5	6

Imagen original

Valor del píxel (columnas) / Valor del píxel (filas)

	4	5	6	7	8	9
4	0	1	1	1	0	1
5	1	0	2	2	1	0
6	1	2	2	0	1	2
7	1	2	0	2	3	0
8	0	1	1	3	4	1
9	1	0	2	0	1	0

Matriz de concurrencia

FIG. 7.77. *Ejemplo de una matriz de coincidencias sobre una imagen simulada de 5 × 5 píxeles con 5* ND *distintos. Izda: imagen original; dcha: matriz resultante.*

8. *Medidas sobre la matriz de concurrencias.* Se trata de una matriz cuadrada, en la que se incluye la frecuencia relativa ($F_{i,j}/n$) de cada combinación espacial entre un determinado ND_i y otro ND_j (esto es, cuantas veces en la imagen el ND_i es contiguo al ND_j). Para reducir el tamaño de la matriz, y simplificar los cálculos, suele reducirse el rango original de la imagen (256 distintos ND), compactándolo en un menor número (habitualmente 16). Pueden calcularse las distintas medidas para una determinada dirección (ángulo entre el píxel central de la ventana y los vecinos) o promediarse las conexiones posibles para 0, 45, 90 y 135° (fig. 7.77). La matriz de concurrencia fue propuesta por Haralick et al. (1973), y se ha utilizado ampliamente para valorar las propiedades espaciales en tareas de clasificación. Sobre esa matriz de coincidencias pueden calcularse varias medidas de textura. Algunas de las más utilizadas en teledetección son las siguientes (Gong *et al.*, 1992; Moller-Jensen, 1990; Smits y Annoni, 1999; Vega-Garcia y Chuvieco, 2006):

a) Homogeneidad:
$$H = \frac{\sum_{i=0,n-1}\sum_{j=0,n-1} p_{i,j}}{(1+(F_i - L_j)^2} \qquad \{7.65\}$$

b) Contraste:
$$C = \sum_{i=0,n-1}\sum_{j=0,n-1}(p_{i,j}(F_i - L_j)^2) \qquad \{7.66\}$$

c) Disimilaridad:
$$EL = \sqrt{(\hat{c}_i - c_i)^2 + (\hat{l}_i - l_i)^2} \qquad \{7.67\}$$

d) Media:
$$M = \sum_{i=0,n-1}\sum_{j=0,n-1}(F_i p_{i,j}) \qquad \{7.68\}$$

e) Desviación típica: $$\mathrm{DT} = \sqrt{\sum_{i=0,n-1} \sum_{j=0,n-1} (p_{i,j}(F_i - M_i)^2)} \quad \{7.69\}$$

f) Segundo momento angular: $$\mathrm{SMA} = \sum_{i=0,n-1} \sum_{j=0,n-1} (p_{i,j})^2 \quad \{7.70\}$$

g) Entropía: $$\mathrm{E} = \sum_{i=0,n-1} \sum_{j=0,n-1} (-p_{i,j} \log(p_{i,j})) \quad \{7.71\}$$

donde $p_{i,j}$ indica la posición *i, j* de la matriz de concurrencia (esto es la frecuencia de los cruces entre el ND *i* y el *j*), *F* y *C* indica la posición en filas y columnas, respectivamente, de esa matriz de concurrencias (en definitiva, cuáles son los ND que se están comparando), M_i señala el valor medio en filas, y *n* el número de columnas y líneas de la matriz (esto es, con cuántos ND distintos se ha realizado el cálculo). En definitiva, p_{ij} mide la probabilidad de que un ND con un valor *i* sea contiguo a otro con un valor *j*.

Hemos incluido dos ejemplos del cálculo de textura sobre la imagen Torre100. Se trata del contraste {7.66}, calculado a partir de la banda 2, utilizando la dirección vertical (fig. 7.76*c*) y el promedio de las cuatro direcciones (fig. 7.76*d*). Por comparación con la textura obtenida mediante desviaciones típicas móviles (7.76*b*), se observa que ambas resaltan bastante bien los contrastes espaciales, siendo tal vez más preciso el obtenido a partir de la matriz de concurrencias para subrayar los bordes, mientras la desviación típica destaca el conjunto de la zona heterogénea. La medida direccional resulta de interés para remarcar los contrastes en ciertas líneas de variación de la imagen.

9. *Dimensión textural.* Las medidas de la matriz de coincidencias son de gran interés, pero presentan algunos problemas, como estar influidas por el contraste tonal de la imagen (y no sólo por el espacial), y resultar algo subjetiva la decisión sobre la distancia máxima para considerar dos píxeles como contiguos (Wang y He, 1990). Para solventar estos problemas, otros autores proponen una medida alternativa basada en las desviaciones locales encontradas en una ventana móvil de 3 × 3 píxeles, el central y los ocho circundantes. El valor de la unidad de textura se calcula a partir de la siguiente fórmula:

$$\mathrm{NUT} = \sum_{j=1,8} 3^{i-1} E_i \quad \{7.72\}$$

donde NUT indica número de unidad de textura y E_i es la medida de textura para cada píxel de la ventana. E_i vale 0 cuando el ND de ese píxel es inferior al ND del píxel central de la ventana, 1 cuando es igual y 2 cuando es superior (fig. 7.78). Los NUT pueden ordenarse de varias formas, dependiendo de qué píxel de la ventana inicie el cálculo y en qué sentido se cuente (a favor o en contra de las agujas del reloj). En cualquier caso, el NUT puede variar entre 0 y 6.560 (3^8). A partir de ese valor puede calcularse el denominado «espectro de textura»; se trata de un histograma que indica la frecuencia de píxeles de la imagen en cada NUT, y permite observar

4	6	8	5	4
5	5	8	7	6
6	7	7	7	9
8	8	4	8	6
9	8	9	5	6

Unidad de textura para el píxel (2,2)

0	2	2
1		2
2	2	2

Valor de E_i

$$NUT = 3^0 \times 0 + 3^1 \times 2 + 3^2 \times 2 + 3^3 \times 2 + 3^4 \times 2 + 3^5 \times 2 + 3^6 \times 2 + 3^7 \times 1 = 4.371$$

FIG. 7.78. *Ejemplo de cálculo de la unidad textural para la imagen de la fig. 7.77.*

los rasgos globales de su contraste espacial. A partir de él se han sugerido calcular algunos índices, como el de simetría entre los valores más bajos y más altos del espectro, o el grado de dirección que presentan las texturas (Wang y He, 1990). Se ha comprobado que estas medidas permiten distinguir algunas cubiertas con escaso contraste espectral, como tipos de minerales o de especies forestales. En este segundo caso, se observó una notable correlación entre los valores de textura derivados a partir de una imagen pancromática SPOT, y algunos parámetros medidos en terreno como el diámetro de copa, altura del árbol, área basal, edad y diámetro a la altura del pecho (Cohen *et al.*, 1995). También se han empleado para reconocer formas de terreno producidas por deslizamientos de ladera (Hervás y Rosin, 2001).

4.2.2. *Medidas de la variación espacial en imágenes clasificadas*

En este caso, partimos de archivos en los que el ND de cada píxel es una etiqueta que identifica la categoría a la que se ha asignado. En consecuencia, aunque se trata de una imagen digital, no pueden aplicarse sobre ella operaciones aritméticas, ya que el ND no indica una relación cuantitativa, sino categórica.

En el campo de ecología del paisaje se han propuesto numerosos índices para medir la estructura espacial de un determinado territorio (Frohn, 1998; O'Neill *et al.*, 1988; Riitters *et al.*, 1995; Saura, 2002). Algunos de ellos se aplican sobre toda la imagen, como los señalados para imágenes cuantitativas; otros, se calculan para ventanas móviles, normalmente de 3 × 3 píxeles, que se van desplazando sobre la imagen. Entre los primeros cabe destacar los siguientes:

1. *Densidad de manchas, calculada como el número de teselas por unidad de superficie.* Como antes indicamos una mancha o tesela *(patch)* se define por un conjunto de píxeles contiguos con la misma categoría. Mediante técnicas de agregación espacial *(clumping)*, puede convertirse una imagen clasificada en una imagen de teselas, etiquetando con el mismo número aquellos píxeles que pertenezcan a la misma categoría temática y sean contiguos. En definitiva, se trata de generar una nueva imagen en donde se identifiquen las manchas de la misma categoría, o dicho de otra forma, se obtenga una numeración del mosaico espacial presente en la escena (fig. 7.79). Esta técnica es bastante común en el entorno de los SIG, en donde se aplica a mapas temáticos con pocas categorías, pero resulta menos frecuente en el ADI. Habitualmente se calcula para imágenes clasificadas, pero también podría hacerse sobre alguna imagen continua, por ejemplo índices de vegetación o temperatura, previamente segmentada en un número determinado de intervalos (Chuvieco,

1	1	1	3	3	3
1	1	2	4	3	3
2	1	2	4	3	3
2	1	2	4	2	1
2	1	2	2	2	1
4	4	2	2	2	1
4	4	4	2	1	1

1	1	1	2	2	2
1	1	3	4	2	2
5	1	3	4	2	2
5	1	3	4	3	7
5	1	3	3	3	7
6	6	3	3	3	7
6	6	6	3	7	7

FIG. 7.79. *Una imagen clasificada (parte superior) puede convertirse en una imagen de manchas (inferior) aplicando técnicas de agregación espacial.*

1999). El cociente entre el número de manchas y la superficie de la imagen nos ofrece una primera valoración sobre la complejidad paisajística de la zona (Dillworth *et al.*, 1994; Ricotta y Retzlaff, 2000). Un área con una densidad alta de manchas indicará un espacio muy fragmentado.

2. *Tamaño.* Además del número, también parece interesante considerar el área media de las manchas, lo que puede fácilmente calcularse a partir de un simple histograma de la imagen de manchas (número de píxeles en cada parcela). Cuanto mayor sea el área media, en principio contaríamos con un espacio más homogéneo.

3. *Forma: compacidad.* Se ha puesto de manifiesto por varios autores el interés de analizar la forma de las manchas presentes en la zona, ya que con la misma superficie un polígono más alargado presenta mayores opciones a la transmisión de especies y menores obstáculos a la influencia mutua entre las manchas que divide. Los índices de forma más habituales tratan de medir la compacidad de los polígonos, como una relación entre su área y perímetro. Éste es el caso del índice F (Gulinck *et al.*, 1991):

$$F = \frac{4\pi A 100}{P^2} \qquad \{7.73\}$$

donde A indica el área y P el perímetro.

Otros índices de compacidad se basan en la relación entre la forma de una mancha determinada y la de una figura geométrica estándar. Así se define el denominado cociente C, que relaciona la relación área-perímetro de un polígono con los de un círculo, la figura geométrica más compacta:

$$C = \sqrt{\frac{Ap}{Ac}} \qquad \{7.74\}$$

donde Ap indica el área del polígono y Ac el correspondiente a un círculo que tuviera el mismo perímetro de ese polígono. Al aumentar C el polígono sería más compacto, menos alargado. Para calcular valores promedio de forma para una determinada zona, algunos autores han propuesto ponderar esos índices de compacidad por el tamaño medio de las teselas, de tal forma que el valor resultante sea menos sensible al cambio de escala o de resolución (Saura y Martínez Millán, 2001).

4. *Forma: dimensión fractal.* Como ya hemos indicado, esta medida intenta cuantificar la complejidad de las formas de líneas, superficies o volúmenes. En caso de tratarse de imágenes clasificadas, su cálculo es más sencillo que con las originales, pues se basa en la relación entre el perímetro y el área de los polígonos que forman el mosaico paisajístico. Una forma sencilla de calcular la dimensión fractal (D), de cada polígono, es la siguiente expresión (Ripple *et al.*, 1991):

$$P \approx A^{D/2} \qquad \{7.75\}$$

donde A indica el área y P el perímetro. El valor medio del conjunto de la imagen se obtendría simplemente promediando D para todos los polígonos que la formen. Otros autores proponen calcular la dimensión para el conjunto de un mapa o imagen clasificada, con objeto de comparar la complejidad geométrica de las manchas que forman el mosaico paisajístico (O'Neill *et al.*, 1988). Bajo esta óptica la dimensión fractal (D) utilizando una regresión los logaritmos del área (A) y el perímetro (P) de los polígonos presentes en el mapa:

$$\log P = a + D/2 \log A \qquad \{7.76\}$$

la constante de la ecuación (a) se denomina constante de proporcionalidad.

Algunos autores han observado que la dimensión fractal está directamente asociada con la complejidad paisajística. En un amplio sector del Este de EE.UU. se comprobó que D ofrecía una valoración numérica de los distintos patrones de uso del suelo; cuando D era pequeño, indicaba que las formas resultaban bastante geométricas, lo que apuntaba a una utilización humana del territorio, frente a otros sectores con mayor presencia de espacios naturales, en donde D ofrecía un valor mucho más alto (O'Neill *et al.*, 1988; Ricotta *et al.*, 1998). Asimismo, se ha comprobado que la dimensión fractal aumenta al disminuirse la resolución espacial del sensor, especialmente si la imagen presenta escasa heterogeneidad inicial (Benson y MacKenzie, 1995).

5. *Forma: cuadratura.* Algunos autores han comprobado que la constante de proporcionalidad (a en la fórmula {7.76} varía a distintas escalas. Frohn, 1998). Por esta razón se ha propuesto una alternativa, que se denomina «cuadratura» (*SqP*: *Squared-pixel*), calculándose como:

$$SqP = 1 - (4A^{1/2}/P) \qquad \{7.77\}$$

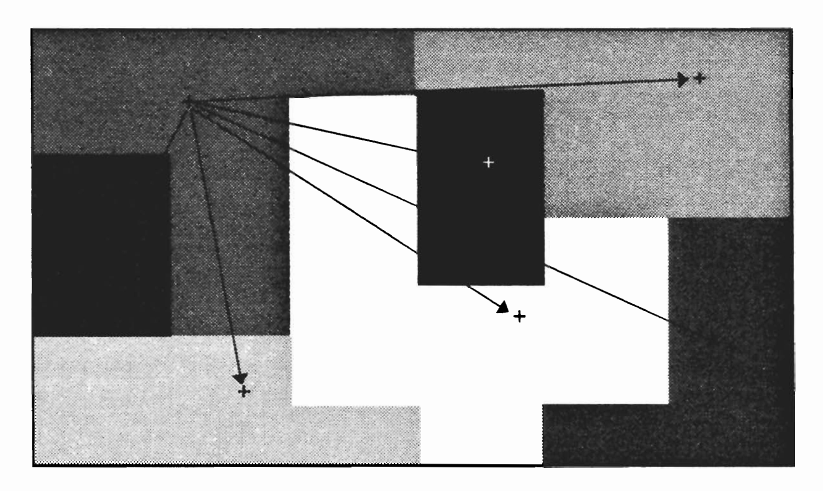


FIG. 7.80. *Calculo de la dispersión promedio entre manchas.*

Este índice varía de 0, cuando el polígono es un cuadrado, a 1 cuando la forma es muy compleja. De acuerdo a Frohn (1998) este índice es más constante a distintas escalas y resoluciones espaciales que la dimensión fractal.

6. *Dispersión.* Hace referencia a la fragmentación de la imagen, y se calcula como la distancia promedio entre los centroides de las distintas manchas (Fig. 7.80). La fragmentación del paisaje es un aspecto de gran importancia en la resistencia al movimiento de especies (Ripple *et al.*, 1991).

Hasta aquí las medidas aplicables al conjunto de las manchas que forman el mosaico de cobertura. Junto a ellas, se pueden calcular otros índices para ventanas locales (normalmente de 3 × 3 píxeles) que se van desplazando consecutivamente en la imagen, midiendo la variabilidad local en las categorías, de forma similar a como vimos con las imágenes de intervalo. En este ámbito, los índices más conocidos son los siguientes:

7. *Diversidad.* Indica la variedad de categorías que pueden encontrarse en una ventana de la imagen (Turner, 1989):

$$D = -\Sigma_{k=1,\,m}\, p_k \ln (p_k) \qquad \{7.78\}$$

donde p_k corresponde a la proporción de la categoría **k** en la ventana considerada y **m** al número de categorías presentes en esa ventana. Cuanto mayor sea la diversidad media, mayor variedad espacial estará presente en la distribución de las cubiertas, o, dicho de otra forma, la zona ofrecerá un mosaico más variado (fig. 7.81). La diversidad está directamente relacionada con la escala de las imágenes, siendo menor al bajar la resolución (Turner et al., 1994).

8. *Dominancia.* Representa la desviación del valor calculado respecto a la máxima diversidad (O'Neill *et al.*, 1988):

$$Do = \ln (m) + \Sigma_{k=1,\,m}\, p_k \ln (p_k) \qquad \{7.79\}$$

1	1	1	1
0	0	0	0
1	1	1	1
0	0	0	0

Div = 0,6365
Dom = 0,0566

1	1	0	0
1	1	0	0
0	0	1	1
0	0	1	1

Div = 0,4900
Dom = 0,0299

1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0

Div = 0,3183
Dom = 0,0283

1	0	1	0
0	1	0	1
1	0	1	0
0	1	0	1

Div = 0,6870
Dom = 0,0062

FIG. 7.81. *Valores de diversidad y dominancia para imágenes simuladas.*

con la misma significación de la fórmula anterior. Cuanto más alto es el valor del índice, mayor predominio tiene una categoría sobre las otras en esa ventana.

9. *Fragmentación.* Estos índices intentan medir el grado de ruptura espacial que ofrece el territorio. Uno de los más utilizados, con esta finalidad, es el índice de Contagio (*Con*), que mide la adyacencia entre categorías frente al máximo posible (Li y Reynolds, 1993; O'Neill *et al.*, 1988):

$$Con = 2 \ln (m) + \Sigma_{i=1,\, m} \Sigma_{k=1,\, m}\, p_{ik} \ln (p_{ik}) \qquad \{7.80\}$$

donde p_{ik} indica la proporción de píxeles en esa ventana en donde la categoría i es limítrofe a la categoría k, y m es el número de clases. Frohn (1998, #3667) propone dividir toda esta fórmula por 2 ln (m), lo que permite escalar el resultado entre 0 y 1. Cuando más próximo a 1 indicará una mayor agregación, mientras valores cercanos a 0 supondrán manchas más pequeñas y dispersas.

El mismo autor propone un indicador más sencillo de fragmentación, que denomina mancha por unidad (*Patch per Unit, PPU*), definido como:

$$PPU = q \,/\, (n \cdot TP) \qquad \{7.81\}$$

donde q indicaría el número de manchas, n el número de píxels y TP el tamaño del píxel. Para este autor, esa medida es más resistente que la compacidad a las variaciones debidas a cambios en la resolución espacial, número de clases, y tamaño de la imagen, mostrando su eficacia en áreas afectadas por procesos de deforestación (Frohn, 1998, #3667).

10. *Matriz de comparación binaria (MCB).* También se dirige a medir la contigüidad de las categorías presentes en una ventana. Se define como (Murphy, 1985):

$$\mathrm{MCB} = \frac{m^2 - \sum_{i=1.m} f_i^2}{2} \qquad \{7.82\}$$

donde f_i indica la frecuencia de aparición de la categoría *i* y *m* el número de categorías. El índice MCB aumenta cuanto mayor es la complejidad espacial, pues considera tanto el número de categorías como su frecuencia. Sin embargo, no tiene en cuenta si las categorías son contiguas o no, por lo que el autor propone complementarlo con algún indicador del número de cambios de categoría que se producen en la ventana considerada.

4.2.3. *Dinámica de la estructura espacial del paisaje*

Las medidas anteriormente revisadas pueden utilizarse tanto para comparar diversos paisajes, como para estudiar la evolución de una zona determinada. En este caso, se trataría de estudiar cómo se transforma la configuración espacial del territorio como resultado de ciertos cambios, debidos a la actividad humana (efecto de ciertas políticas sobre el uso del suelo), o de algún evento esporádico (inundaciones, erupciones volcánicas o incendios). Con este enfoque multitemporal se han abordado numerosos trabajos en ecología del paisaje (Ne'eman *et al.*, 1999; O'Neill *et al.*, 1988; Reinhardt y Ringleb, 1990; Turner *et al.*, 1994). La explicación de esos cambios se basa en factores de índole socio-económico, o en las propias variables geográficas (suelo, topografía, litología, etc.) (Pastor y Broshart, 1990).

Un marco para la aplicación de estas medidas a imágenes de satélite es el seguimiento del efecto del fuego sobre la estructura espacial del paisaje (Chuvieco, 1999), tomando como ejemplo el incendio de Buñol, antes comentado. Para evaluar este efecto paisajístico a distintos niveles de resolución, se compararon imágenes Landsat-TM y NOAA-AVHRR, adquiridas casi simultáneamente antes y después del fuego. La figura 21* recoge un sector de estas imágenes sobre la zona afectada por el incendio. Junto al evidente efecto de la resolución espacial, se muestra una tendencia común entre ambas imágenes, mostrándose con claridad el patrón del área quemada.

Para homogeneizar las medidas antes comentadas y evitar el efecto subjetivo de una clasificación, se aplicaron directamente sobre los índices de vegetación (NDVI), calculados para ambos sensores, a partir de los valores de reflectividad. Sobre las imágenes de los NDVI se calculó la media de unos perfiles y el índice de autocorrelación de Moran. Tras segmentar los NDVI a 12, 10, 8, 5 y 3 intervalos,[4] calculamos sobre ellos el número de manchas, su compacidad, la diversidad promedio y la dimensión fractal. Los cálculos se realizaron de la misma forma para las imágenes TM y AVHRR.

Las tablas 7.17 y 7.18 recogen los resultados de esta comparación. Como puede observarse, prácticamente en todas las medidas calculadas, la imagen posterior al fuego presenta una mayor homogeneidad espacial, tanto en las imágenes TM como en las AVHRR. La única excepción es la desviación típica del perfil, que aumenta tras el incendio en la imagen AVHRR. Este dato no tiene una gran relevancia, ya que puede ser originado por ruido, puesto que esa línea sólo tiene 15 píxeles AVHRR, lo que resulta poco significativo.

4. Fue necesario segmentar la imagen TM del NDVI porque, con el rango original de categorías (250), el número de manchas que se obtenían excedía la memoria dinámica del programa.

TABLA 7.17. *Variación de la estructura del paisaje a consecuencia del fuego (medidas aplicadas a las imágenes de los NDVI (Chuvieco, 1999)*

	TM-Antes del fuego	*TM-Después del fuego*	*AVHRR-Antes del fuego*	*AVHRR-Después del fuego*
I de Moran	0,871	0,919	0,714	0,90
Desviación típica del perfil	11,66	10,14	2,73	3,77
Media textural	18,05	15,68	7,59	6,56

TABLA 7.18. *Variación de la estructura del paisaje a consecuencia del fuego (medidas aplicadas a 8 intervalos de NVDI (Chuvieco, 1999)*

	TM-Antes del fuego	*TM-Después del fuego*	*AVHRR-Antes del fuego*	*AVHRR-Después del fuego*
Área media	47,48	84,01	1.060,00	1.986,00
Compacidad media	0,289	0,171	0,57	0,58
Desviación típica de la compacidad	0,458	0,210	0,19	0,15
Diversidad media	0,766	0,491	1,06	0,81
Dimensión fractal	2,250	2,272	2,26	2,29

El índice de Moran indica una mayor homogeneidad para la imagen posterior al fuego. El valor de la autocorrelación espacial aumenta tanto en la TM como en la AVHRR, de forma más brusca en esta última (un 125 % frente a un 105 % de la imagen TM). Por el contrario, disminuye la textura media, obtenida a partir de la matriz de coincidencias antes comentada, lo que también indica una mayor homogeneidad después del fuego. La figura 7.82 incluye el semi-variograma de las imágenes TM anterior y posterior al fuego. Este gráfico se construyó a partir de una muestra aleatoria de 1.000 píxeles, considerando un promedio de todas las direcciones. En el trazado general, se observa cómo la imagen posterior al incendio ofrece una mayor varianza, especialmente para las distancias superiores a 500 metros. Esto indica que hay mayor contraste tonal en la segunda imagen, como consecuencia de la presencia de un gran sector quemado. Podría deducirse, por tanto, que la imagen post-incendio es más heterogénea espacialmente, contradiciendo las conclusiones que proporcionan otro tipo de índices. Sin embargo, esta mayor heterogeneidad no es tan clara para las distancias más cortas, por debajo de 210 m (7 píxeles), en las que la imagen de julio equipara o supera la varianza espacial de la de agosto. Podríamos concluir, en este caso, que la aparición de una mancha quemada incrementa la textura espacial para el conjunto del mosaico, pero no para las relaciones de vecindad, que aparecen como más similares a consecuencia del fuego, confirmando los análisis de los otros índices.

Respecto al número de manchas, en todas las segmentaciones de la escala original del NDVI que hemos realizado, se observa una disminución para las imágenes posteriores al fuego (figura 7.83). Para los datos TM la caída más brusca entre las dos fechas se registra con una segmentación en 12 niveles de NDVI. En esas imá-

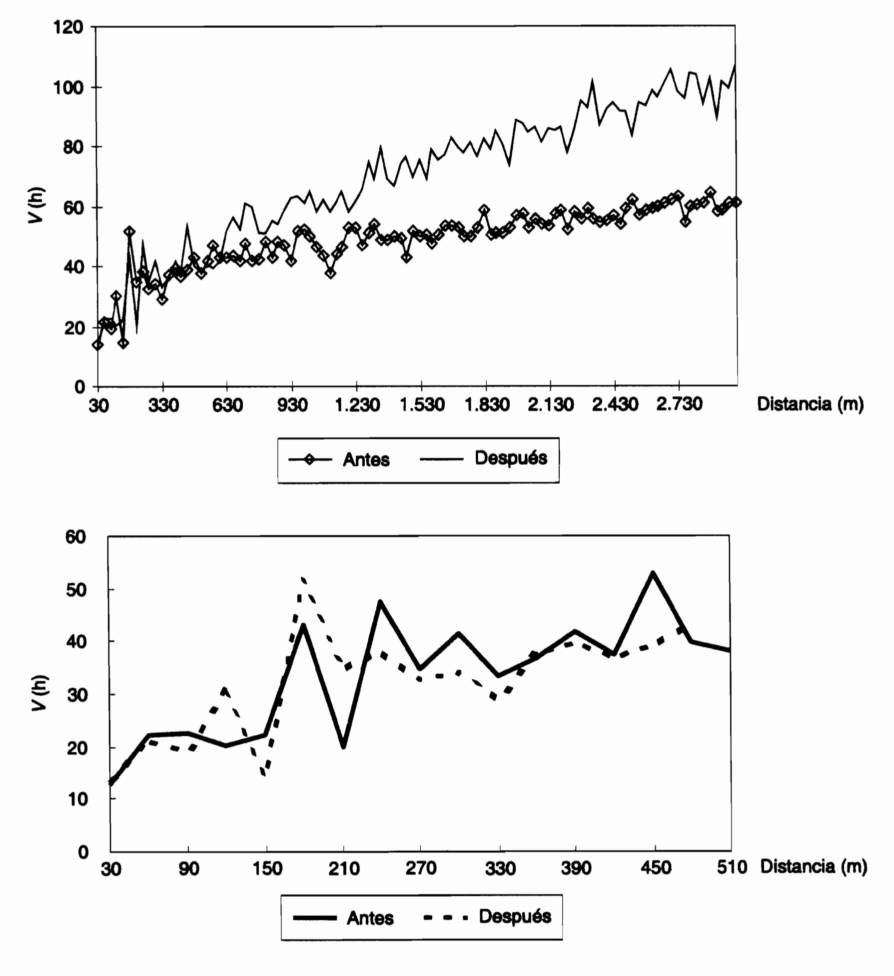


FIG. 7.82. *Semi-variogramas para las imágenes TM anterior y posterior al incendio.*

genes, se observa una reducción del 58 % en el número de manchas en la imagen posterior al fuego.

Para la imagen AVHRR la reducción del número de manchas también es consistente, tanto para los 250 valores originales del NDVI, como para las distintas segmentaciones (de 12 a 3 grupos). El máximo decremento ocurre con 10 rangos de NDVI, en donde se pierde el 42 % del número de manchas previo al incendio.

Para el caso concreto de segmentar las imágenes en 8 niveles de NDVI, calculamos algunas medidas de compacidad y diversidad (tabla 7.18). La superficie media de las manchas, por ejemplo, indica la formación de un mosaico más homogéneo en la imagen TM post-incendio, que casi duplica la superficie media por mancha previa al fuego. En otras palabras, los polígonos de vegetación quemada tienden a ser mayores que los previos, lo que implica que el fuego homogeneiza el territorio, al menos a corto plazo. La imagen AVHRR ofrece la misma tendencia que la TM, con un notable aumento de la superficie media para la imagen posterior al fuego.

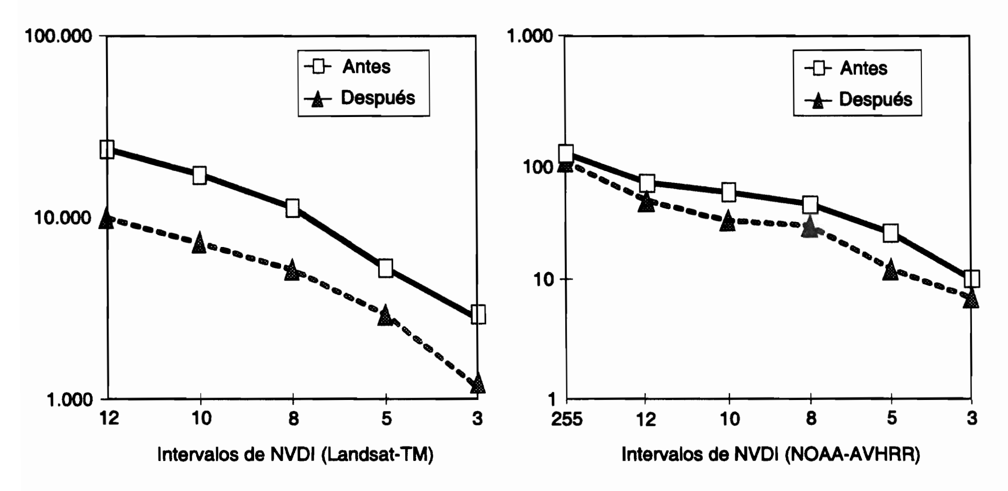


FIG. 7.83. *Disminución del número de manchas tras el incendio.*

En cuanto a la compacidad, para el caso concreto de los 8 rangos de NDVI, se observa una disminución del valor medio a consecuencia del incendio, de modo más claro en la imagen TM que, gracias a su mayor resolución, ofrece mejores posibilidades para el análisis de formas. Las manchas, en consecuencia, tienden a ser más alargadas, probablemente por el efecto del relieve en la dispersión del fuego. La desviación típica de la compacidad también es menor después del fuego, indicando una mayor homogeneidad en la forma de los grupos.

La geometría fractal se incrementa tras el fuego, tanto para la imagen TM como para la AVHRR, indicando que los polígonos son más irregulares a consecuencia del incendio, lo que es coherente con la disminución de la compacidad.

Finalmente, la diversidad media de las manchas es también mucho menor tras el incendio, confirmando una vez más el efecto homogeneizador del fuego. Este efecto se observa tanto en alta como en baja resolución espacial, aunque en ésta resulta menos evidente.

Similares análisis podemos realizar sobre otro tipo de aplicaciones. Por ejemplo, pueden aplicarse medidas de cambio en la forma y tamaño para evaluar la evolución de las dunas en un estudio de desertificación (Collado *et al.*, 2002) (fig. 7.84), o analizar el cambio en la estructura espacial del territorio que producen los fenómenos de deforestación (Frohn, 1998). En este contexto, puede resultar de gran interés comparar los patrones reales, para distintos marcos espaciales, niveles de resolución o grados de abundancia, con simulaciones de estructura espacial del paisaje, realizadas utilizando métodos estocásticos, lo que facilita ver la sensibilidad de las distintas medidas comentadas a los cambios en esos factores de control (Saura, 2002).

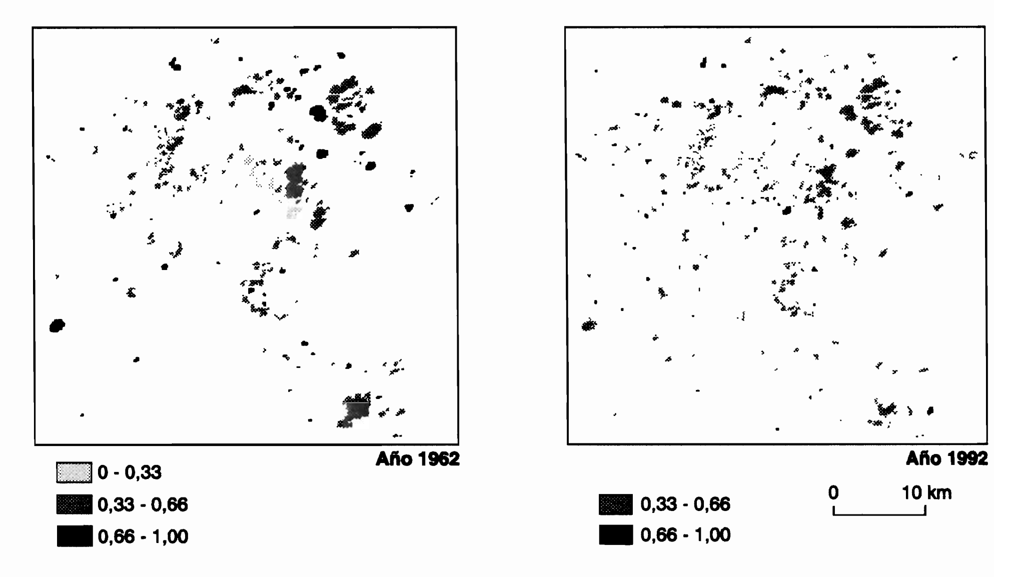


FIG. 7.84. *Cambios en los valores de compacidad de los cuerpos dunares entre 1962 y 1992. Área de San Luis (Argentina): (Collado* et al., *2002).*

CAPÍTULO 8

VERIFICACIÓN DE RESULTADOS

«La vida se nos da,
y la merecemos dándola.»
RABINDRANATH TAGORE, *Gitangali*

1. Necesidad de verificar resultados

Una vez obtenidos los resultados de cualquier tipo de interpretación de las imágenes, ya sea visual o digital, resulta obligado verificar la calidad de los mismos, de cara a comprobar la validez tanto del producto generado como del método propuesto. Frecuentemente, la verificación de resultados se considera como el último paso de la clasificación digital, por lo que podría considerarse parte de ella. Ahora bien, estrictamente, debe también incluirse en la interpretación visual de imágenes, así como en otros tipos de análisis digital, como sería la generación de variables continuas (temperatura, clorofila, por ejemplo) o la detección de cambios. Por esta razón, nos ha parecido más conveniente incluir este tema como un capítulo aparte, en lugar de cómo un epígrafe en el dedicado a la clasificación digital.

La verificación de resultados permite al usuario valorar su grado de acuerdo con la realidad, o, dicho de otro modo, el riesgo que asume al tomar decisiones sobre la información que ha generado. Por ejemplo, si el interés del trabajo es ofrecer una estimación del rendimiento de un determinado cultivo, la estimación del error nos permitiría conocer en qué márgenes se mueve el rendimiento real (lógicamente, con un cierto nivel de confianza en las estimaciones), de cara a tomar decisiones sobre la comercialización futura de ese producto o el tipo de ayudas que requiere su producción.

Este proceso de verificación siempre requiere que comparemos nuestros resultados con una fuente externa, que se considere fiel representante de la realidad presente en el terreno en el momento de adquirir la imagen. Como lógicamente no es posible tener esa información de referencia para todo el área de estudio (si así fuera, no tendría sentido generarla de nuevo mediante teledetección), el proceso de verificación requiere aplicar técnicas de muestreo que nos permitan estimar, con la mayor precisión y el menor coste posible, el error que contienen nuestros resultados. En consecuencia, este proceso no es nada más que un ejemplo concreto del mues-

treo espacial, que se dirige a estimar la variable error a partir de seleccionar una muestra suficientemente representativa de las condiciones del terreno, en el mismo lugar y fecha en que se adquirió la imagen. Posteriormente, el análisis estadístico de esos pares de observaciones (realidad-resultados) nos permitirá estimar numéricamente ese grado de error.

Siendo más sistemáticos en la exposición, podemos indicar que la verificación de resultados incluye las siguientes fases (Congalton y Green, 1999):

— Diseño del muestreo, señalando cuántas parcelas deben muestrearse y cómo se seleccionan.
— Recolectar datos de referencia y resultados sobre esas parcelas seleccionadas en la muestra. Esta fase incluye la selección de las fuentes de la verdad-terreno, el procedimiento para recolectar los datos de referencia, y la extracción de los resultados del análisis digital.
— Comparar los datos de referencia y nuestros resultados, mediante distintos test estadísticos y la generación de una matriz de confusión.
— Análisis de los errores encontrados, validación de la calidad del proceso y, si es el caso, cuantificación de la fiabilidad de las distintas metodologías aplicadas.
— Antes de tratar con más detalle cada una de estas fases, vamos a comentar algunos aspectos más generales de la verificación de resultados, exponiendo los procedimientos que se han seguido hasta ahora y las principales fuentes de error que puede presentar el proceso.

2. Medidas de la fiabilidad

La estimación de la exactitud alcanzada por los resultados de una interpretación de imágenes se ha realizado por varios procedimientos. Obviamente, el más sencillo es una valoración cualitativa, que lleva al intérprete a dar por buenos unos productos si ofrecen una visión acorde con su conocimiento de la realidad (podríamos sintetizarlo coloquialmente, con la expresión «parece bueno»). Aunque pueda parecer inaceptable, de hecho todavía sigue siendo éste el procedimiento más universal de valorar los resultados de la interpretación de imágenes en teledetección, ya que esta valoración subjetiva es evidentemente mucho menos costosa y más rápida que una verificación rigurosa. Ahora bien, como es lógico, de este examen pocas consecuencias científicas pueden deducirse: ¿puedo estimar el estado hídrico del cultivo con suficiente precisión para emplear la teledetección operativamente en mejorar el riego?, ¿el método de clasificación que propongo es más preciso para esta aplicación que el utilizado convencionalmente?, son ejemplos de preguntas que no pueden responderse si no se valora numéricamente la precisión de nuestros resultados.

En orden de dificultad, el siguiente método para valorar los resultados implica compararlos con una fuente estadística convencional, como pueden ser los inventarios agrícolas o forestales que se hacen mediante estimaciones de terreno o encuestas a las cámaras agrarias. Esta opción, que suele denominarse verificación no espacial *(non-site specific)*, en el mejor de los casos nos ofrece el grado de ajuste entre las dos fuentes (teledetección y fuente estadística), pero no informa sobre dónde se

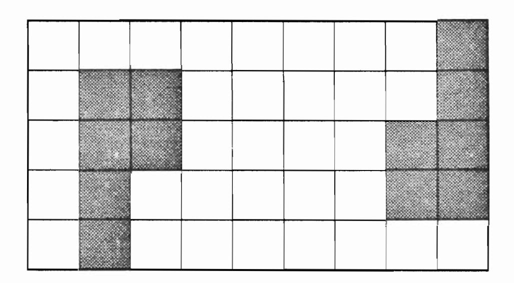
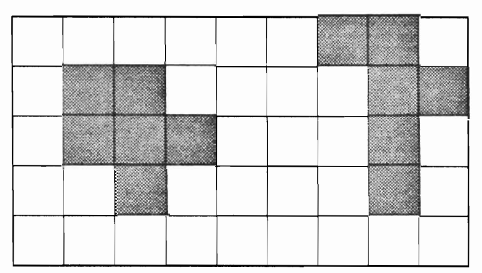



FIG. 8.1. *Problemas que plantea la verificación no espacial. Los valores totales de una categoría pueden ser los mismos, pero no así su distribución espacial.*

presentan los errores. Además, como en cualquier resultado habrá errores por exceso (comisión) y por defecto (omisión), podría obtenerse un saldo ajustado con un notable margen de error (fig. 8.1). En otras palabras, suponiendo al documento de referencia como plenamente fiable, esta medida sólo indica el porcentaje de error, pero no su localización sobre el mapa. Por otro lado, tampoco identifica las confusiones entre categorías que producen ese margen de error, además de que no siempre resulta sencillo ajustar la leyenda de la fuente convencional con la obtenida a partir de imágenes de satélite (GDTA-CEE, 1982).

El tercer método de verificación implica utilizar como datos de comprobación los mismos que se hayan empleado para ajustar el modelo. Esta opción reduce el coste del trabajo de campo, ya que no supone una inversión añadida a la propia realización el modelo, pero incluye un importante sesgo positivo en la valoración de los resultados. Por ejemplo, si usamos las mismas áreas para entrenar y verificar la clasificación, la fiabilidad estimada será más alta que la real, ya que esas áreas sirven para definir estadísticamente a las distintas categorías, y, en consecuencia, parece lógico que los píxeles incluidos en ellas tengan una mayor probabilidad de clasificación certera que el resto de los píxeles de la imagen. De igual forma, si medimos el error de un ajuste empírico para obtener una variable biofísica (por ejemplo, temperatura), a partir de los mismos puntos que se empleen para generarla, el error de la estimación será más bajo que el encontrado para observaciones independientes, pues precisamente el ajuste se genera minimizando la distancia a esos puntos (fig. 8.2).

Finalmente, la vía más adecuada para verificar es seleccionar una serie de muestras independientes, no utilizadas en la obtención de resultados, que permitan generar una medida estadísticamente más sólida del acuerdo entre imagen y verdad-terreno. Lógicamente, la selección y recolección de esas muestras supone un coste adicional al proyecto, que no repercute en una mejora de su fiabilidad, sino sólo en la medida de ésta. Esta nueva inversión, en tiempo y dinero, explica las reticencias que puede implicar esta fase, aunque no cabe duda que repercute positivamente sobre la solidez del método y los resultados que se ofrecen.

A partir de la obtención de esas muestras independientes puede estimarse el error de los resultados, ya sea mediante algún estadístico continuo (típicamente el error medio cuadrático) en variables de intervalo (clorofila, temperatura, contenido de agua), ya mediante una tabla o matriz de confusión, en donde se resuman los

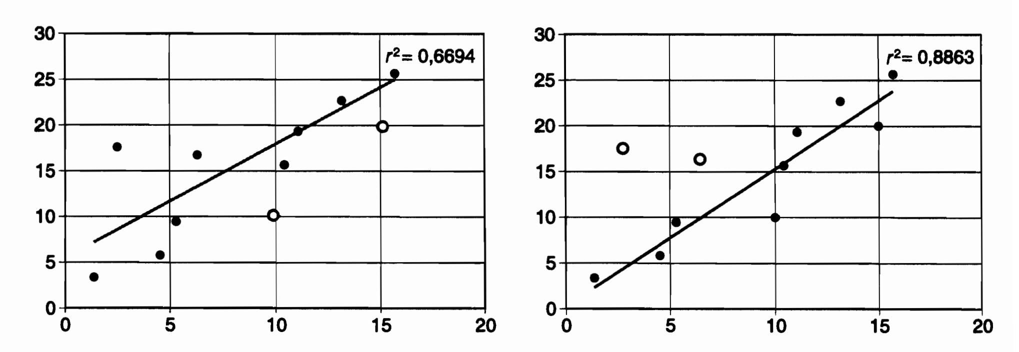


FIG. 8.2. *El empleo de los mismos puntos para calibrar y verificar el modelo implica una estimación sesgada del error. Los círculos blancos indican puntos que se extraen del ajuste, lo que modifica el mismo, aumentando el error en esos puntos.*

acuerdos y desacuerdos entre clases del mapa y del terreno. Más tarde comentaremos cómo analizar esta matriz. Puesto que la medida de la fiabilidad se estima a partir de un muestreo, en ambos casos su valor real se mueve entre unos márgenes, tanto más próximos al valor medio cuanto mayor sea al tamaño de la muestra y menor el grado de error. Al tratarse de un muestreo espacial, el resultado nos permite conocer no sólo el grado global de acierto, sino también entre qué categorías se producen las confusiones, facilitando una reflexión sobre la leyenda elegida o el método empleado. Este tipo de verificaciones se califican como «espaciales» *(site specific)*, al ofrecer asimismo una imagen del patrón espacial del error.

Adicionalmente, esta verificación espacial y cuantitativa ofrece la notable ventaja de poder ajustar las estimaciones de superficie a partir de la fiabilidad estimada para la clasificación (Hay, 1988). Los valores de error pueden utilizarse para corregir las estimaciones de superficie asignadas a cada tipo de cobertura. Por ejemplo, si la clasificación nos señala una superficie de trigo correspondiente a 680 ha, y hemos encontrado un error de omisión correspondiente a un 15 %, podría estimarse la superficie real cultivada en 782 ha (680 + 0,15 = 680). Este enfoque fue utilizado, por ejemplo, para recalcular las estadísticas de área quemada en Canadá a partir del análisis de imágenes de baja resolución y de perímetros generados por los servicios forestales (Fraser *et al.*, 2004).

3. Fuentes de error en una clasificación temática

La fiabilidad de los resultados depende de distintas variables que conviene tener en cuenta a la hora de valorar los errores estimados en el proceso de verificación. Por un lado, las características del sensor con el que trabajamos, que quizá no ofrezca la resolución necesaria para esa determinada aplicación. Por otro, el método de trabajo, que puede no ser capaz de extraer toda la información contenida en la imagen. Un tercer grupo de factores hace referencia a la propia complejidad del área de estudio. Finalmente, también es preciso considerar los propios errores del proceso de verificación, que lleven a una estimación poco certera del error realmente presente en la imagen.

3.1. Limitaciones del sensor

Dejando a un lado los posibles errores en la adquisición de la imagen debidos a fallos en el funcionamiento del sensor, de la plataforma que lo sustenta, o de los sistemas de recepción y/o grabación de la señal, las limitaciones intrínsecas del sensor pueden suponer una fuente importante de problemas, especialmente cuando se hayan señalado unos objetivos poco realistas para los datos disponibles. Este sería el caso cuando se intente obtener un determinado nivel de desagregación en la leyenda inapropiado para la aptitud de un determinado sensor, que no cuente con la resolución espacial o espectral para discriminar esas categorías con cierta garantía. Como es bien sabido, el intento de establecer subdivisiones en una clase temática implica un mayor riesgo de error, al pretender discriminar cubiertas que muy probablemente serán similares espectralmente. En un estudio sobre el sur de Alemania, se comprobó cómo la combinación de las clases «baja densidad urbana» y «alta densidad urbana» en una clase común «urbana», aumentó la precisión de la cartografía final en un 83 %, mientras la inclusión de «bosque», en lugar de «bosque caducifolio» y «bosque perennifolio» incrementó la precisión a un 88 % (Schneider, 1980). Similares conclusiones se han extraído por otros autores, en el intento de establecer distintas densidades de edificación en zonas urbanas (Toll, 1984).

En pocas palabras, como se señaló en el cap. 4, es muy importante adecuar la elección del sensor y del método de tratamiento a los requerimientos de escala cartográfica y tipo de categorías que demande un determinado estudio. De otra manera, el riesgo de error se incrementará. Como es obvio, generar mapas de áreas quemadas con imágenes de baja resolución (AVHRR o MODIS) es más barato y rápido que hacerlo con imágenes de media (Landsat-TM o SPOT-HRV), pero también implica menor fiabilidad, tanto en la detección de áreas como en la delimitación rigurosa de cada una de ellas. Lógicamente, la elección del sensor más conveniente será un compromiso entre la inversión que supone y el nivel de error que puede tolerarse.

3.2. Métodos de análisis

Hemos visto a lo largo de esta obra una amplia variedad de técnicas visuales y digitales para extraer información temática de las imágenes. La elección entre unas u otras dependerá de los recursos disponibles al intérprete y de su propia formación técnica. En cualquier caso, conviene recordar que los errores de una clasificación no son necesariamente inherentes a las características de las imágenes que utilizamos, sino que también pueden deberse a una falta de pericia del intérprete para aplicar el método más apropiado a ese problema. Por ejemplo, si en un determinado trabajo se concluye que las imágenes Landsat-TM no son apropiadas para delimitar áreas urbanas, al observar discriminaciones bastante pobres, conviene revisar si el intérprete ha utilizado los criterios más apropiados para este tipo de coberturas. Si ese estudio no hubiera empleado más que técnicas relativamente rudimentarias de interpretación (clasificación estadística convencional), sin recurrir a variables texturales o clasificadores de contexto que son más apropiados para el ámbito urbano, entonces

los pobres resultados serían más achacables a la metodología que al sensor. De la misma forma podríamos juzgar a algún intérprete que obtenga errores elevados en el cálculo de temperaturas de superficie, sin aplicar previamente métodos sólidos para eliminar el efecto atmosférico o las diferencias de emisividad.

En sentido amplio, podríamos incluir entre las deficiencias del método de interpretación los errores derivados de una incorrecta selección de la fecha de adquisición de la imagen. En el caso de las cubiertas vegetales, resulta muy conveniente considerar su dinamismo estacional, de cara a establecer el período más apropiado para abordar su discriminación. Si la imagen se adquiere en una fecha inadecuada, es posible que aparezcan errores de asignación, de otro modo solventables. Por ejemplo, en imágenes de verano, pueden presentarse problemas para discriminar, digitalmente, núcleos rurales y parcelas cerealistas recién cosechadas (Chuvieco, 1985*a*). El problema se deriva de su comportamiento espectral, muy cercano en esas fechas, puesto que los tejados de estos núcleos suelen fabricarse con el mismo material del suelo agrícola. Evidentemente, esta confusión puede obviarse utilizando imágenes de primavera, cuando estos campos aparecen cultivados, mostrando un comportamiento muy distinto de las zonas edificadas. En otro tipo de cubiertas esta discriminación resulta mucho más problemática, por cuanto sus componentes básicos son muy similares. El ejemplo más típico sería la confusión entre áreas residenciales y bosques caducifolios. Su comportamiento espectral resulta bastante parejo a lo largo del año, ya que la cubierta arbolada (similar en ambas categorías) es la más influyente en la generación de la señal detectada por el sensor. En este sentido, se evidencia la necesidad de contar con otros criterios de interpretación, como la textura o el contexto.

3.3. Estructura del territorio

Los errores relacionados con la estructura del territorio incluyen aquellas confusiones derivadas de la disposición espacial con que se presentan las cubiertas objeto de estudio. Aquí pueden incluirse aspectos como la forma, orientación y tamaño de las parcelas, así como el contraste espacial entre cubiertas vecinas y el grado de mezcla en los distintos tipos de cubierta.

El efecto de la morfología parcelaria resulta especialmente sensible en aquellas regiones que han sufrido una ocupación milenaria del territorio, que tienden a presentar propiedades de muy pequeña extensión, inferior incluso al tamaño del píxel. Como consecuencia, el sensor detecta una señal radiométrica promedio entre dos o más cubiertas, haciendo prácticamente imposible su discriminación (fig. 8.3). El efecto, conocido como error de frontera, es muy habitual en aplicaciones agrícolas, especialmente en los paisajes con parcelamiento muy minucioso.

Estrechamente conectado con este problema, se encuentra el efecto de la disposición espacial de los tipos de cubierta. Si existe un claro contraste espectral entre cubiertas vecinas, éstas serán más fácilmente separables que si ofrecen un comportamiento similar, ya que el sensor, al cambiar de una a otra, podrá detectar una señal suficientemente discrepante de tal modo que podamos interpretarla como perteneciente a una cubierta distinta (fig. 8.4). Por ejemplo, un núcleo rural rodeado de

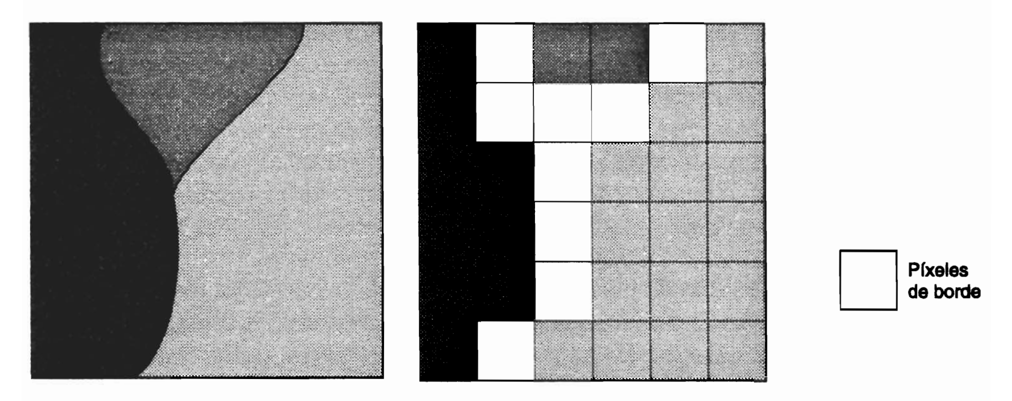


FIG. 8.3. *Consecuencias del error de frontera. Los píxeles de borde registrarán una señal radiométrica intermedia entre dos o más tipos de cobertura.*

cultivos en regadío, resulta más fácilmente discriminable que si se enmarca en un sector cerealista de secano, ya que esta cubierta cuenta con una respuesta más similar a los núcleos rurales, especialmente cuando se trabaja con imágenes estivales.

En cuanto al grado de mezcla entre cubiertas, puede afirmarse que supone un problema casi insoluble, al menos cuando se aborda el trabajo sólo a partir del valor radiométrico de cada píxel. Otros criterios más abstractos, como estructura, tex-

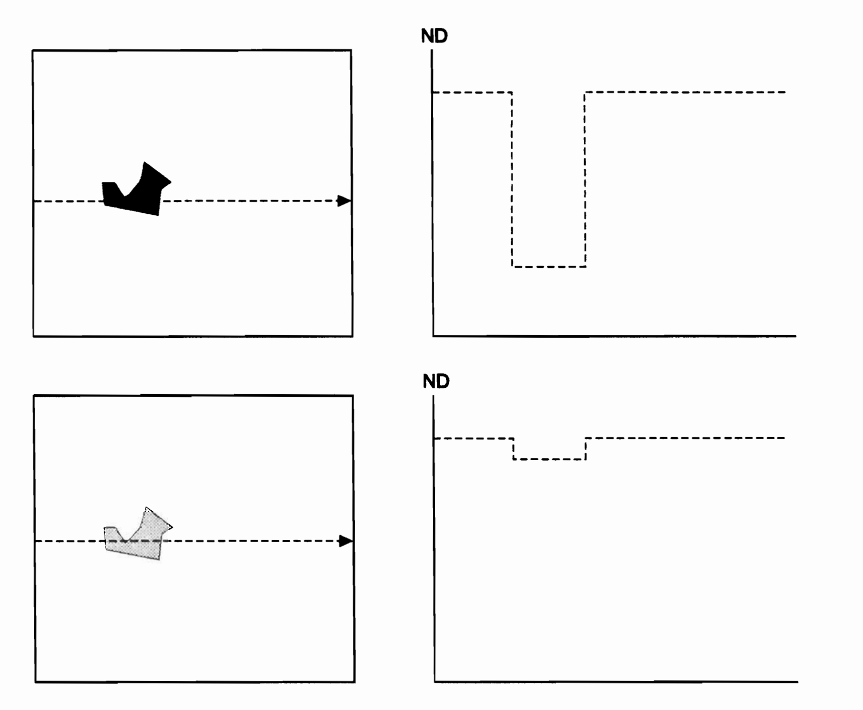


FIG. 8.4. *El efecto del contraste radiométrico entre cubiertas vecinas se observa en los perfiles trazados sobre un área de alto y bajo contraste.*

tura o asociación, comunes en análisis visual, pueden paliar ese problema, si bien la distinción de rasgos de tamaño inferior al del píxel sólo se realiza por aproximación. Este efecto es especialmente evidente en cubiertas agrícolas, cuando se produce asociación de cultivos en la misma parcela. En el caso de categorías forestales, implica la combinación entre diversas especies de árboles, y de éstas con matorral y pastizales. Una alternativa para estudiar este tipo de situaciones es acudir a técnicas de modelado subpíxel (ALME, clasificación borrosa), si bien no siempre consiguen mejorar significativamente los resultados en paisajes complejos.

La influencia del tipo de paisaje en los errores de la clasificación se ha puesto en evidencia al estudiar la distribución espacial de los patrones de error. Algunos trabajos han demostrado que existe una auto-correlación espacial significativa entre los píxeles mal clasificados (Congalton, 1988*b*). Dicho de otra forma, la aparición de un píxel erróneo está estrechamente relacionada con su ubicación espacial, ya que los errores están notablemente influidos por la estructura del territorio. Esa tendencia a la formación de áreas de error es más clara en aquellas imágenes que muestran menor complejidad espacial; esto es, con patrones de distribución más sistemáticos, como ocurre en el caso de las áreas agrícolas. Por su parte, en los paisajes más complejos, como son las áreas urbanas o los espacios de vegetación natural, los errores son menos sistemáticos (fig. 8.5).

Por último, podemos señalar un grupo de errores de asignación debidos a las condiciones medioambientales de una determinada cubierta. Como ya hemos visto, la distinta orientación, pendiente, densidad y estado fenológico con que aparece una categoría temática, implica una variabilidad espectral en torno al comportamiento tipo de esa categoría. Tal dispersión dificulta la caracterización espectral de una clase, provocando solapes y confusiones con categorías vecinas.

3.4. Proceso de verificación

Una última fuente de error en la medida de la fiabilidad puede relacionarse, no tanto con el error en sí de nuestros resultados, sino más bien con el propio proceso de verificación, que no está exento de problemas (Congalton y Green, 1999). En este capítulo podemos considerar varios aspectos.

Por un lado, las propias metodologías de obtención de los datos de terreno. Como es sabido, algunas de las variables estimables con teledetección pueden obtenerse en terreno a partir de varios procedimientos, pero todos suelen presentar problemas, ya sea por el coste o la lentitud del proceso, ya por la fiabilidad. Por ejemplo, para el caso de la estimación del agua en las plantas, existen varias opciones: cámaras de presión osmótica, métodos gravimétricos, empleo de varillas estándar (Slavik, 1974), que pueden facilitar estimaciones diversas para la misma planta. Además, hay que considerar el ruido que implica la diferencia de escala entre la imagen y la medición de terreno, al tratarse de unidades de observación distintas.

Otro aspecto a tener en cuenta es el posible ruido causado por la falta de coherencia entre las personas que realizan la validación. Cuando la verificación se realiza por varias personas simultáneamente puede haber diferencias de interpretación entre ellas, especialmente cuando la variable a medir en terreno puede ser fruto de

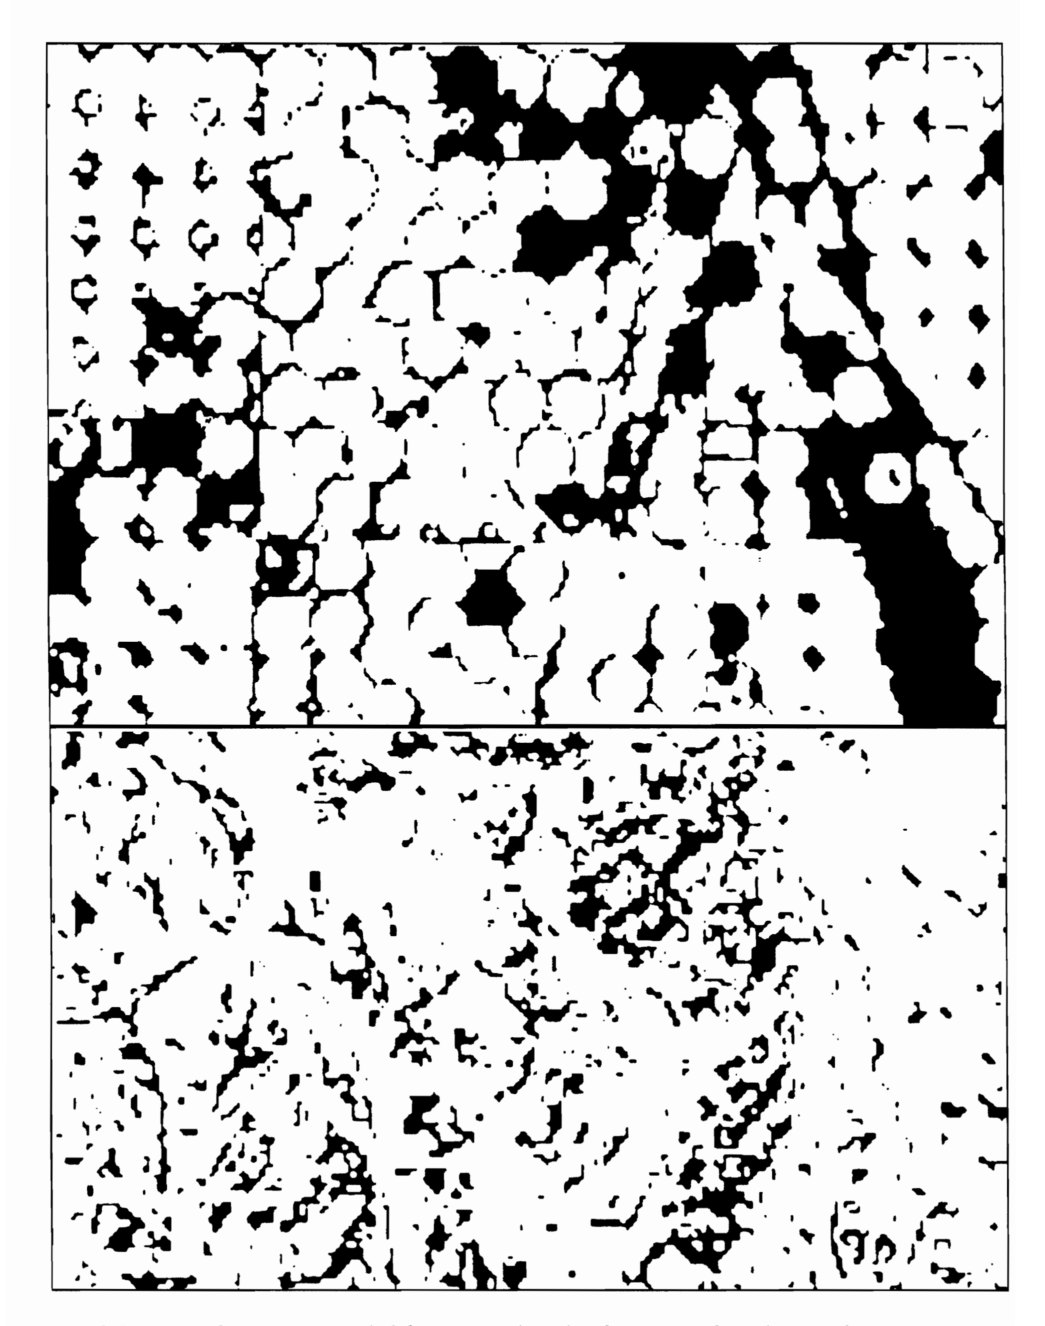


FIG. 8.5. *Distribución espacial del error en las clasificaciones digitales. En la parte superior aparece una imagen correspondiente a una zona agrícola; en la inferior a un área forestal (Congalton, 1984).*

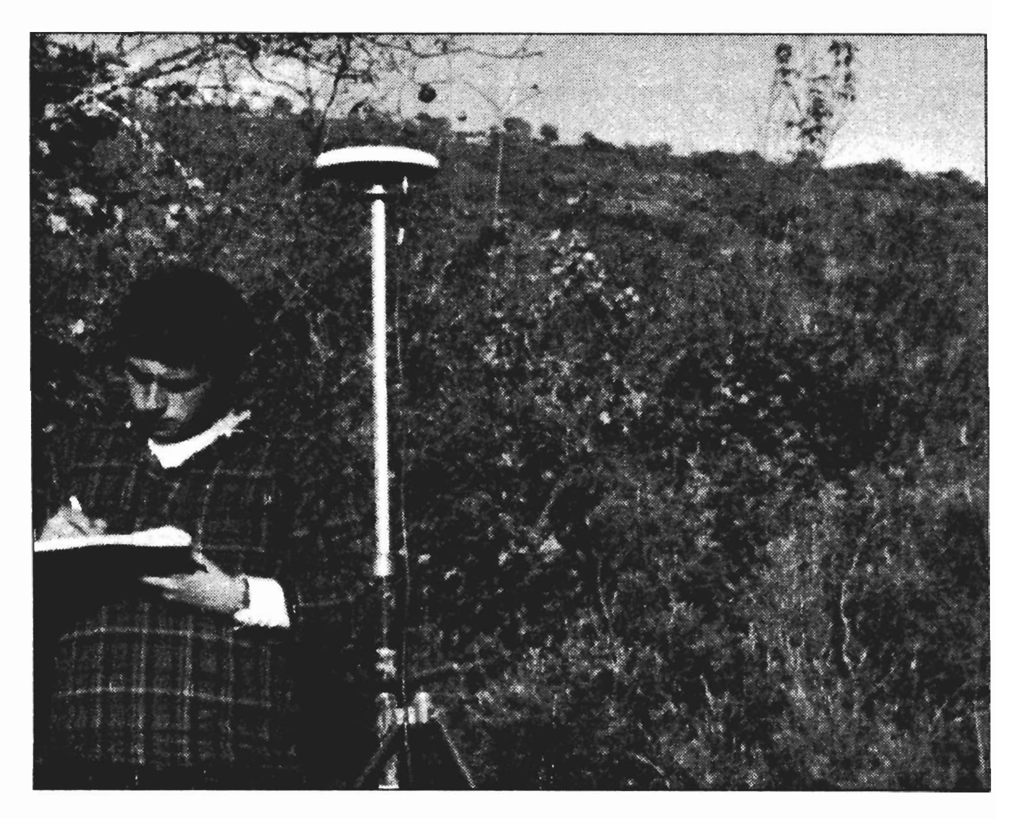


FIG. 8.6. *Localización de parcelas de muestreo con sistemas GPS.*

una cierta subjetividad. En este sentido, resulta clave definir con precisión las distintas categorías temáticas, dejando al encuestador el menor margen de interpretabilidad posible. Por ejemplo, hay que establecer taxativamente qué se entiende por una superficie arbolada (especies forestales por encima de una cierta altura promedio), o qué densidad marcará el límite entre las clases pastizal y matorral.

Otro factor que dificulta el proceso de validación hace referencia a los posibles problemas en la georreferenciación de la imagen o de la parcela de terreno que estemos usando para verificar. Esto supondrá extraer valores de referencia en un lugar distinto al que estamos intentando validar. El empleo de cartografía de gran escala, y mejor aún de los sistemas de posicionamiento global (GPS), que permiten una georreferenciación bastante precisa sobre el terreno (fig. 8.6), puede aliviar ese problema, siempre que la precisión del instrumento sea acorde con la resolución espacial de la imagen. En trabajos con imágenes de resolución media, incluso GPS de uso comercial pueden facilitar suficiente precisión, pero si se pretende trabajar con LIDAR u otros sensores aeroportados (Riaño *et al.*, 2004a; Riaño *et al.*, 2004*b*), la exactitud requerida sólo es abordable con receptores mucho más profesionales.

Por otro lado, conviene considerar asimismo que el documento de referencia puede incluir errores. Cuando se utiliza una fotografía aérea como verdad-terreno, la foto-interpretación puede no ser completamente precisa o tratarse de una fecha distinta a la adquisición de la imagen, en cuyo caso estaremos incluyendo como

error lo que sería más bien cambio temporal. En este concepto entrarían también los problemas derivados de validar los resultados de una imagen de baja resolución con otra de alta, asumiendo que esta última expresa bien la verdad-terreno, cuando en realidad está midiendo la misma variable que la primera, y por tanto puede tener también similares errores de interpretación.

Finalmente, otro posible error del proceso de verificación se presentaría cuando la inspección en terreno no sea coetánea a la adquisición de la imagen. Ese desfase temporal sería especialmente crítico cuando se midiera una variable muy dinámica (como sería la temperatura del agua, por ejemplo). Más adelante comentaremos algunos elementos a tener en cuenta para minimizar estos posibles errores.

4. Diseño del muestreo para la verificación

El diseño y desarrollo del muestreo supone la columna vertebral del proceso de verificación. Al igual que en otras aplicaciones, el muestreo espacial sirve en este caso para seleccionar una pequeña parte del área de estudio, de forma tal que sea suficientemente representativa del conjunto. Esa semejanza con la población de referencia debe conseguirse, además, minimizando el tamaño de la muestra, con objeto de reducir los costes del proceso de verificación. En definitiva, un buen muestreo sería aquel que permita extraer la mejor estimación posible de la variable objetivo con el menor tamaño de muestra posible. Esto implica que el esquema de muestreo elegido tiene que permitir realizar estimaciones estadísticas a partir de la muestra, ser sencillo de implementar y analizar, recoger adecuadamente la variabilidad espacial del error y ser de bajo coste. La selección de uno u otro tipo de muestreo dependerá de una serie de factores (Congalton y Green, 1999; Stehman, 1999*b*): ¿cómo se distribuye la información en el área de estudio?, ¿cuál es la unidad de muestreo más apropiada?, ¿cuántas muestras elegir?, ¿cómo elegirlas?

4.1. Distribución de la información

Este aspecto hace referencia al tipo y continuidad espacial de la variable que estamos verificando. En otras palabras, el esquema de muestreo debe considerar si se trata de una variable discreta o continua, y cómo se distribuye esa variable en el espacio, principalmente si presenta rasgos acusados de auto-correlación espacial.

En cuanto al tipo de variables, en verificación de clasificaciones temáticas tendremos que manejar técnicas estadísticas aptas para variables nominales. En consecuencia, el muestreo se basará sobre distribuciones categóricas, siendo la más frecuente la binomial (acierto/error). Por el contrario, cuando se pretenda verificar una variable continua, como la temperatura o el contenido de humedad de la vegetación, el muestreo puede basarse en distribuciones continuas, como la distribución normal o la de Poisson.

En cuanto al patrón espacial de la variable, conviene disponer de una estimación de su grado de auto-correlación espacial (Congalton, 1988*b*). Como antes señalamos, la asociación espacial del error tiende a presentar unos patrones diversos

si se trata de superficies naturales o artificiales, principalmente debido al error de frontera. En el caso de paisajes agrícolas, los errores tenderán a asimilarse al patrón parcelario, presentando una estructura regular, mientras serán más aleatorios en el caso de zonas forestales. Este fenómeno puede invalidar la asunción de independencia estadística en la elección de la muestra, clave en cualquier muestreo.

4.2. Unidad de muestreo

La unidad de muestreo hace referencia al elemento sobre el que se extraerá la información de referencia para comparar con nuestros resultados. Con frecuencia se identifica con el píxel, pero no tiene porqué. De hecho, en muchas ocasiones será más conveniente utilizar como unidad de muestreo un grupo de píxeles (por ejemplo, una ventana de 3 × 3), lo que permitirá reducir los posibles errores de la georreferenciación. También puede utilizarse como unidad muestral cada uno de los polígonos temáticos que se hayan definido en la clasificación. En este caso, y puesto que la verificación debe realizarse con los mismos esquemas de la clasificación, no convendrá que la unidad de muestreo sea más pequeña que la mínima unidad cartografiable. De otra manera, se podrían señalar como errores lo que en realidad sería fruto de la generalización.

4.3. Tipos de muestreo

Entre los parámetros arriba enunciados, la elección del método más idóneo de muestreo parece el más controvertido entre los especialistas. Los esquemas más regularmente empleados en el proceso de verificación son (Congalton, 1988*a*; Congalton, 1991; Rosenfeld, 1982; Rosenfeld *et al.*, 1982; Stehman, 1999*b*; Stehman, 1992) (fig. 8.7):

1. *Aleatorio simple.* Los elementos a verificar se eligen de tal forma que todos cuenten con la misma probabilidad de ser seleccionados, y que la elección de uno no influya en la del siguiente. Gracias a este carácter probabilístico, el muestreo aleatorio es bastante sólido estadísticamente, si bien presenta problemas en su aplicación espacial, por cuanto puede suponer elevados costes de desplazamiento. Por otra parte, existe cierta probabilidad de no recoger adecuadamente la variación espacial del error presente en la imagen clasificada, y de que algunas categorías, poco frecuentes, no estén representadas en la muestra.
2. *Aleatorio estratificado.* La muestra se selecciona dividiendo la población en regiones o estratos, de acuerdo a una variable auxiliar (altitud o las mismas categorías temáticas que se han clasificado, por ejemplo). Es más complejo de diseñar que el anterior, pero aporta información sobre subconjuntos de la población, además de reducir el error de muestreo siempre que la variable auxiliar esté claramente relacionada con la distribución del error.
3. *Sistemático.* La muestra se distribuye a intervalos regulares, a partir de un punto de origen señalado aleatoriamente. Garantiza un muestreo completo de la

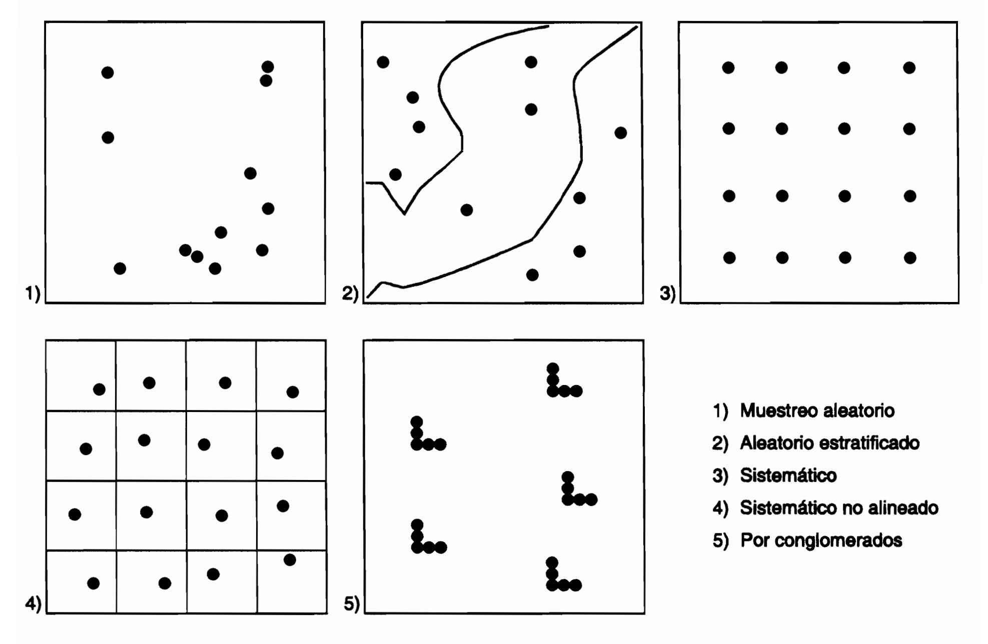


FIG. 8.7. *Tipos de muestreo aplicados a la verificación.*

superficie a verificar, pero puede facilitar estimaciones erróneas si existe algún tipo de patrón periódico en el área observada (geometría de las parcelas, por ejemplo). Por otro lado, no asegura una estimación probabilística, por cuanto no existe aleatoriedad en la selección de las observaciones.

4. *Sistemático no alineado.* Modifica el esquema anterior, gracias a variar aleatoriamente —en cada línea y columna del muestreo— una coordenada, manteniendo fija la otra. Esto permite introducir una cierta aleatoriedad en la elección de la muestra, mientras reduce el sesgo debido a la periodicidad. Por otra parte, sigue garantizando una revisión completa del territorio.

5. *Por conglomerados.* Se selecciona como unidad de muestra un grupo de observaciones, denominado conglomerado (*cluster*), en lugar de individuos aislados. En otras palabras, en cada punto a verificar se toman varias muestras, en puntos vecinos al elegido aleatoriamente, y de acuerdo a un esquema prefijado. Por ejemplo, un conglomerado podría constituirse por cinco puntos, a cierta distancia del punto central y siguiendo una forma de L. Además, pueden plantearse muestreos en varias fases, cambiando en cada una la unidad de muestreo. Este método reduce los costes de transporte, pero resulta más complejo y, normalmente, menos preciso que los anteriores.

De entre ellos, el muestreo sistemático no alineado ha sido profusamente empleado en tareas de verificación de clasificaciones (Dozier y Strahler, 1983; Rosenfeld *et al.*, 1982; Stehman, 1992), gracias a las propiedades arriba enunciadas. Otros autores recomiendan métodos alternativos, como el aleatorio simple (Hord y Brooner, 1976), el estratificado por categorías (Ginevan, 1979) o el muestreo por conglomerados (Todd *et al.*, 1980). No obstante, parece conveniente comentar con más de-

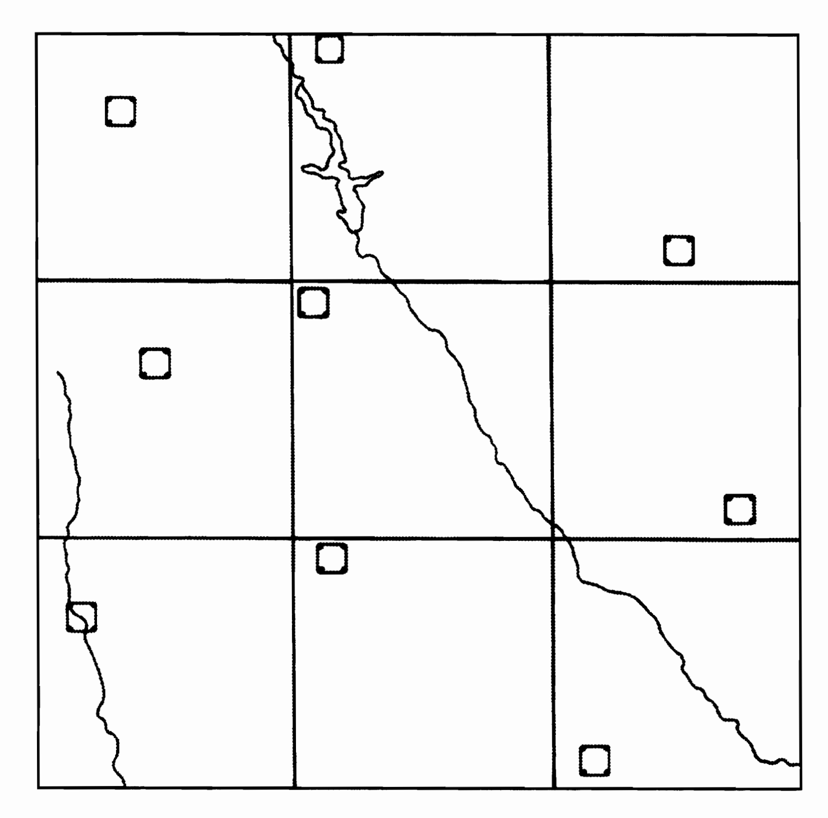


FIG. 8.8. *Diagrama de desarrollo del muestreo sistemático no alineado.*

talle el muestreo sistemático no alineado, en razón de su frecuente presencia en trabajos de verificación de clasificaciones.

En este método, la elección de la muestra parte, habitualmente, de dividir el área de estudio en una malla regular de rectángulos, que podrían hacerse coincidir con la cuadrícula UTM. Sobre cada uno de ellos, se elige uno o varios puntos de muestreo, de acuerdo a un proceso de selección sistemático, pero no alineado. Esto quiere decir, que, en cada una de las columnas y filas de esa matriz de rectángulos, las coordenadas de cada punto de observación se eligen manteniendo un eje constante, y variando el otro aleatoriamente (fig. 8.8). De esta forma, se introduce un cierto rasgo de aleatoriedad, a la vez que se mantiene una observación global del territorio (Berry y Baker, 1968).

Los trabajos experimentales de Congalton (1984; 1988*a*) parecen aportar una visión más rigurosa para esta elección. Este autor partió de una serie de tres imágenes clasificadas, de ámbito agrícola, ganadero y forestal, para las que se contaba con una cartografía de referencia suficientemente detallada. Esto permitió superponer digitalmente las clasificaciones obtenidas con los mapas de la verdad-terreno, obteniendo una medida precisa del error total incluido en cada una de las tres imágenes. A partir de esta medida, aplicó los cinco esquemas de muestreo antes aludidos, para estudiar cuál de ellos la estimaba con mayor rigor. Con objeto de investigar la acción de diversos parámetros, se seleccionaron distintos tamaños de muestra y se aplicó el

muestreo según varios escenarios. Las conclusiones de estos trabajos situaron al muestreo aleatorio simple como el esquema más eficaz, seguido del aleatorio estratificado. El muestreo por conglomerados ofreció también buenos resultados, siendo especialmente apropiado en el caso de verificar grandes superficies en donde los costes de desplazamiento pueden ser cruciales. En ese caso, Congalton recomendaba el empleo de pequeños conglomerados, entre 5 y 25 píxeles de tamaño según la variabilidad de la imagen. El autor desaconseja el empleo del muestreo sistemático y del sistemático no alineado, especialmente cuando la imagen tienda a presentar un error periódico, como es el caso de las zonas agrícolas o cubiertas por pastizales. Por ello, sugiere aplicar una evaluación previa de la auto-correlación espacial (Congalton, 1988*b*), que puede facilitar la decisión sobre qué tipo de muestreo resulta más conveniente. En trabajos más recientes, sugiere utilizar diversos métodos combinados, extrayendo muestras parciales de cada uno de ellos, a fin de solventar los problemas y aprovechar las ventajas que presentan (Congalton y Green, 1999).

Nada comenta Congalton sobre los costes de desplazamiento asociados a cada uno de estos esquemas de muestreo. Por otras referencias, y nuestra propia experiencia, podemos establecer una jerarquía desde el muestreo aleatorio simple —estratificado— sistemático y por conglomerados, de mayor a menor coste. Asimismo, en la valoración de Congalton, no se considera la estimación de la fiabilidad por categorías. En caso de que la clasificación haya incluido cubiertas poco representadas en la zona de estudio, el muestreo aleatorio puede obviarlas, al no implicar un examen sistemático de toda la superficie. Por esta razón, aun con ser de gran interés, los trabajos de Congalton no anulan completamente el empleo del muestreo sistemático no alineado en trabajos de verificación.

4.4. Tamaño de la muestra

Como en cualquier muestreo estadístico, el tamaño de la muestra depende del nivel de probabilidad, o de confianza, que quiera otorgarse a la estimación, del error tolerable en la estimación y de la propia heterogeneidad de la variable. La muestra será tanto más grande cuanto mayor nivel de confianza, menor margen de error y mayor variabilidad incluya el muestreo.

En caso de que quiera verificarse una variable cuantitativa, como contenido de agua en plantas, temperatura o turbidez del agua, el tamaño de la muestra para unos determinados requisitos puede calcularse utilizando la fórmula apropiada al tipo de muestreo que hayamos seleccionado. En términos generales, el parámetro a estimar (en nuestro caso, la diferencia entre la variable estimada de la imagen y la medida en terreno) se encontrará a una cierta distancia del valor estimado en el muestreo:

$$\bar{x} = \hat{x} \pm z \cdot \text{EM} \qquad \{8.1\}$$

donde $\bar{x}$ sería la media poblacional (el error real presente en la imagen), $\hat{x}$ el valor de error estimado en el muestreo, z el nivel de probabilidad que queramos darle a la estimación y EM, el error del muestreo, que en cada tipo de muestreo se calcula de modo diferente. Este EM depende del tamaño de la muestra y de la varianza de la

variable (de la heterogeneidad de la distribución de errores, en nuestro caso). En definitiva, $z \cdot EM$ nos indica el intervalo de confianza (L) en torno al cual se moverá el error realmente presente en la imagen. Para calcular el tamaño de la muestra, necesitamos fijar ese margen de confianza, en función de la precisión que queramos darle a los resultados. Eligiendo un valor de probabilidad (z) estándar, podremos estimar el tamaño de la muestra para el tipo de muestreo que hayamos seleccionado. Por ejemplo, para el aleatorio simple:

$$L^2 = z^2 \cdot \frac{s^2}{n} \frac{(N-n)}{N} \qquad \{8.2\}$$

donde L es el intervalo de error tolerable, z la abcisa de la curva normal para un valor determinado de probabilidad, s^2 la varianza muestral, N el tamaño de la población, y n el tamaño de la muestra. Para muestras grandes ($n > 30$), puede prescindirse del último término ($(N - n)/N$) que se conoce como corrección para poblaciones finitas. Para calcular el tamaño de la muestra necesaria para un determinado muestreo, necesitamos fijar un margen de error permitido (L), un determinado rango de probabilidad (que fija el valor z) y estimar de alguna manera la varianza muestral (s^2). En definitiva, despejando de la fórmula anterior, el tamaño de la muestra se calcula como:

$$n = \frac{z^2 s^2}{L^2 + \frac{s^2 z^2}{N}} \qquad \{8.3\}$$

De estos parámetros, el más complicado de cuantificar es la varianza muestral, ya que habitualmente sólo se conoce al terminar el muestreo, por lo que es preciso estimarlo a priori de alguna forma. Algunas posibilidades son: estimarla de muestreos previos o a partir del rango de la variable (se ha sugerido un valor de $s = 0{,}29$ veces el rango para una distribución regular y de $s = 0{,}21$ veces el rango para una sesgada).

Por ejemplo, si queremos estimar la precisión del cálculo de temperatura que hemos realizado sobre una zona de 5.000 km^2, con un nivel de probabilidad del 95 % ($z = 1{,}96$), y admitimos un error en la estimación de 1,5°, habiendo observado un rango de temperaturas de 20,69° (por tanto, $s = 0{,}29 \cdot 20{,}69 = 6$), podemos sustituir en {8.3}:

$$n = \frac{1{,}96^2 \cdot 6^2}{1{,}5^2 + \frac{6^2 \cdot 1{,}96^2}{5.000}} = 31{,}221$$

lo que quiere decir que tendríamos que medir en 32 puntos de muestreo (asumiendo que la unidad de muestreo es una superficie de 1 km^2) para obtener ese margen de precisión.

Para el caso de un imagen clasificada, en donde la variable no es cuantitativa sino categórica, se recomienda emplear la distribución binomial de probabilidad. La expresión más sencilla (sin considerar la corrección para poblaciones finitas) sería:

$$n = \frac{z^2 pq}{L^2} \qquad \{8.4\}$$

donde z sigue siendo la abcisa de la curva normal; p indica el porcentaje estimado de aciertos; q, el de errores ($q = 1 - p$), y L, el nivel permitido de error. El valor de p y q puede estimarse a partir de datos auxiliares o simplemente igualarse a 50.

Por ejemplo, si quiere conocerse el número necesario de puntos de verificación para estimar, con el 95 % de probabilidad, el error de un determinado mapa, suponiendo que los aciertos son del 85 %, y el máximo de error permitido es de ±5 %, tendríamos:

$$n = \frac{1{,}96^2 \cdot 85 \cdot 15}{5^2} = 195{,}92$$

lo que indica que, al menos, se han de tomar 196 muestras para obtener los niveles de precisión marcados en el muestreo. Este tamaño puede resultar muy pequeño si hacemos referencia al total de píxeles de la imagen. Hay que tener en cuenta que en esta aplicación no resulta muy apropiado seguir las reglas clásicas de la estadística, ya que el número de píxeles de referencia (el total del área clasificada) es muy grande. En consecuencia, algunos autores proponen un valor mínimo de muestras para obtener una estimación fiable del error. Este umbral se sitúa en 50 píxeles por cada clase temática (Congalton, 1991; Hay, 1979). Se aconseja, además, realizar el muestreo para todas las clases por separado, partiendo de la clase con menor extensión. Esta marcará la proporción del área a muestrear para el resto de las categorías.

Como muestra de trabajo de verificación, hemos seleccionado para este capítulo el desarrollado para una cartografía de modelos de combustibles forestales (Salas y Chuvieco, 1995). Ese trabajo se basó en la clasificación digital de una imagen Landsat-TM, adquirida en julio de 1988 sobre el sector oriental de la Sierra de Gredos. En el área de estudio, de unos 500 km^2, se tomaron 144 parcelas que se visitaron en el terreno para observar los modelos de combustible presentes en la zona. El total de píxeles verificados fue de 9.515, recogiendo el mínimo de 50 píxeles por categoría señalado previamente.

5. **Recogida de la información**

Una vez diseñado el método y tamaño de la muestra, y localizados los puntos muestrales, el paso siguiente de la verificación consiste en obtener, para cada uno de ellos, el valor de la variable a verificar o la clase temática de referencia y el estimado a partir de la interpretación de la imagen.



FIG. 8.9. *Los trabajos de campo resultan claves para validar resultados de la interpretación de imágenes.*

El valor de referencia puede obtenerse por medición directa o a partir de fuentes de información auxiliares. La medición u observación directa requiere realizar un trabajo de campo simultáneo a la adquisición de la imagen. Si la variable es muy dinámica es clave esa sincronía con la imagen, mientras en caso contrario puede aceptarse un cierto desfase. Como es lógico, es importante que el instrumento de medición en terreno esté bien calibrado, de tal forma que el valor que consideremos como referencia sea un fiel reflejo de la variación real de la variable. Si medimos clorofila o contenido de agua en vegetación con un instrumento que también incluye un margen de error en la estimación, la verificación de la fiabilidad obtenida por la imagen será un tanto incierta, de ahí la importancia de extraer buena información de campo para validar los modelos de interpretación (fig. 8.9).

Muy frecuente en estos trabajos de verificación es el empleo de radiómetros de campo, aunque también se emplean en la fase de calibración y entrenamiento (Barret y Curtis, 1999*a*). Estos equipos nos permiten medir la misma zona observada por el satélite en condiciones muy controladas y sin influencia de la atmósfera, facilitando además un análisis de la variabilidad espacial de las firmas espectrales (fig. 8.10).

Para el caso de verificar mapas de clasificación, el intérprete en terreno tiene que aplicar la misma definición de categorías temáticas que se hizo para clasificar la imagen. Como antes indicamos, esto es especialmente crítico cuando hay varias personas que realizan este chequeo de campo (Congalton y Green, 1999). Una adecuada coordinación entre esas personas puede evitar subjetividades en la asignación de las clases de referencia. Por ejemplo, convendrá definir en términos muy precisos las clases heterogéneas: mosaico de cultivos, pastizal-matorral, vegetación poco densa, etc. Esos términos resultan relativamente vagos y pueden dar lugar a incoherencias en la recogida de la información en terreno. Una forma de reducir este pro-

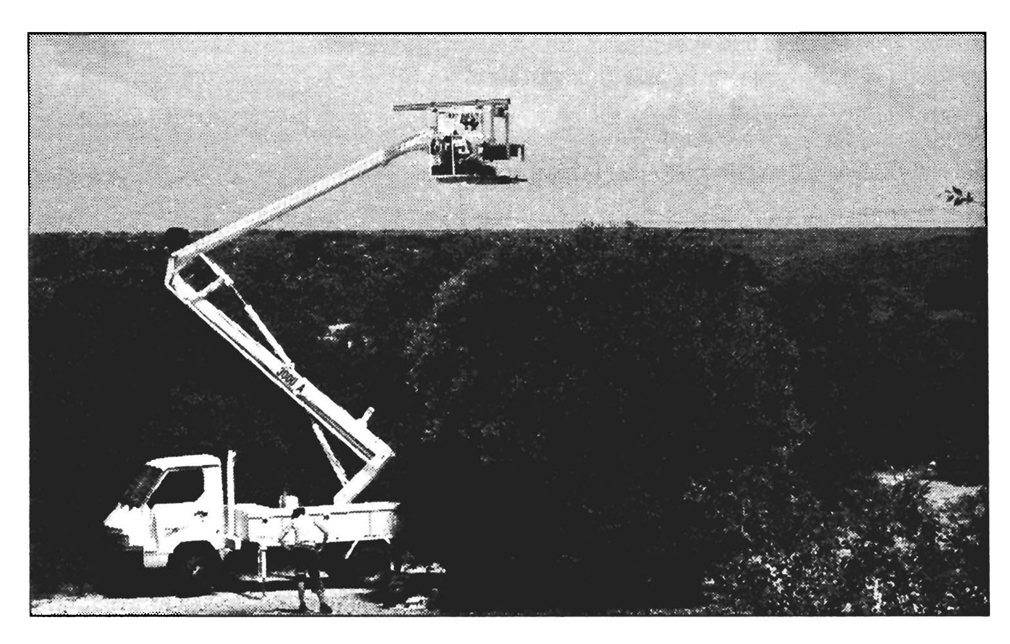


FIG. 8.10. *El empleo de espectro-radiómetros es muy frecuente para verificar y calibrar datos en teledetección.*

blema es señalar claves dicotómicas para clasificar en el campo, como serían las basadas en porcentajes de cubierta (área forestal se entiende como aquella con una cubierta superior al 75 % arbolado, con alturas superiores a 4 m, por ejemplo).

La alternativa a los trabajos de campo, siempre costosos y lentos, es el empleo de documentos auxiliares de mayor detalle (imágenes de mayor resolución espacial, fotografías áreas), o de sensores automáticos (temperatura, clorofila, aerosoles...). Para el caso de las clasificaciones de la imagen, la fotografía aérea se ha utilizado frecuentemente para validar resultados. La decisión es acertada si ambas fuentes, foto aérea e imagen, son de la misma o similar fecha. De lo contrario, puede plantear problemas de consistencia temporal, importantes cuando las zonas sean muy dinámicas. Por otro lado, la foto-interpretación puede llevar consigo errores, lo que implicaría introducir un ruido en el proceso de verificación.

Para el caso de las variables cuantitativas, es importante que los sensores estén bien calibrados y faciliten buena resolución temporal, de cara a extraer el dato más cercano al momento de adquisición de la imagen. Esto suele cumplirse en caso de las estaciones meteorológicas automáticas, si bien hay que tener en cuenta que éstas miden las características del aire y no del suelo como hace el sensor remoto (para la temperatura), por lo que las comparaciones no pueden ser directas.

Respecto a qué valor de la imagen extraemos para comparar con el de referencia, puede optarse por seleccionar píxeles aislados, o por grupos de píxeles (típicamente un promedio de una ventana de 3×3). Esta segunda opción es la más habitual, ya que reduce el impacto de pequeños errores de georreferenciación que pueda incluir la imagen. En el caso de imágenes clasificadas, la extracción debería realizarse sobre la misma unidad mínima de información que recoja el mapa resulta-

do, ya sean píxeles individuales o polígonos de un determinado tamaño, seleccionando la clase puntual o la más frecuente, según los casos..

6. Medidas del error para variables continuas

Una vez obtenidos los datos de referencia, puede calcularse el error de la estimación que hayamos realizado a partir de la imagen utilizando cualquier prueba estadística de significación. Lo más habitual es emplear el error medio cuadrático (RMSE), definido ya en el epígrafe de corrección geométrica de imágenes, si bien en este caso se trata de una sola variable (para la corrección teníamos dos, fila y columna). Por tanto, la fórmula {6.66} quedaría como:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1,n} (\hat{x}_i - x_i)^2}{n}} \qquad \{8.5\}$$

donde $\hat{x}$ indicaría el valor estimado a partir de la imagen y x_i el medido en terreno. Como antes indicamos, el valor del RMSE será sólo una estimación del error realmente presente en nuestra variable, puesto que se ha obtenido por un muestreo. Deberíamos aplicar los intervalos de confianza vistos en {8.1} para estimar el margen real en el que se mueve el error de la variable deducida de la imagen.

Para una estimación más rigurosa del error del ajuste, la validación debería medirse con puntos no utilizados en la calibración del modelo. De otro modo, el muestreo estaría sesgado positivamente. Puesto que la estimación de una variable de intervalo se realiza frecuentemente a partir de modelos empíricos, como ya vimos en el epígrafe 1 del cap. 7, necesitaríamos una amplia colección de observaciones en campo, unas reservadas para la calibración del modelo, y otras para la verificación. Esta amplia disponibilidad no resulta muy frecuente, ya que las medidas de campo son siempre muy costosas. Si prescindimos de algunas de ellas para reservarlas en la verificación, el ajuste empírico puede quedar comprometido y ser poco significativo. Para obviar este problema, algunos autores han propuesto —en el marco de la georreferenciación de imágenes, pero también puede aplicarse a cualquier variable de intervalo— lo que se denomina validación cruzada, en la que se calcula una variante del RMSE (McGwire, 1996):

$$\text{RMSE}^* = \sqrt{\frac{\sum_{i=1,n} (f(\hat{x}_i) - x_i)^2}{n}} \qquad \{8.6\}$$

donde $f(\hat{x})$ indicaría la función de ajuste sin utilizar el punto i. Esta medida se calcula para todas las observaciones disponibles, obteniendo finalmente un promedio del error con todas ellas.

7. Medidas del error para imágenes clasificadas

7.1. La matriz de confusión

Para el caso de verificar una imagen clasificada, la recogida de la clase de referencia y la extracción del valor de la imagen permitirá obtener un listado de puntos de verificación, para los que poseemos tanto su cobertura real como la deducida por la clasificación. Con esa lista puede generarse una tabla, denominada «matriz de confusión» puesto que recoge los conflictos que se presentan entre categorías. En esta matriz las columnas suelen indicar las clases de referencia, y las filas las categorías deducidas de la clasificación. Lógicamente ambas tendrán el mismo número y significado; se trata, en suma, de una matriz cuadrada: $n \times n$, donde n indica el número de categorías (tabla 8.1). La diagonal de esta matriz expresa el número de puntos de verificación en donde se produce acuerdo entre las dos fuentes (mapa y realidad), mientras los marginales suponen errores de asignación. La relación entre el número de puntos correctamente asignados y el total expresa la fiabilidad global del mapa. Los residuales en columnas indican tipos de cubierta real que no se incluyeron en el mapa, mientras los residuales en filas implican cubiertas del mapa que no se ajustan a la realidad. En definitiva, representan los errores de omisión y de comisión, respectivamente (Aronoff, 1982; Story y Congalton, 1986).

El interés de estas tablas de confusión proviene de su capacidad para plasmar los conflictos entre categorías. De esta forma, no sólo conocemos la fiabilidad global de la clasificación, sino también la exactitud conseguida para cada una de las clases, así como los principales conflictos entre ellas.

En la tabla 8.2 se incluye un ejemplo de una de estas matrices, lo que permite observar las principales confusiones presentes en esa clasificación. En este ejemplo, se trataba de discriminar entre cubiertas vegetales en función de su comportamiento frente al fuego de superficie (Salas y Chuvieco, 1995). Ese objetivo es complicado de abordar mediante teledetección, ya que algunas clases se ven enmascaradas por un dosel vegetal continuo, además de la propia dificultad para distinguir categorías mixtas (pastizal o matorral arbolado). Las principales confusiones que se observan en las tablas 8.2 y 8.3 afectan a los distintos tipos de matorral (modelos de combustible 4, 5 y 6, sólo separables por la altura, lo que resulta complejo de diferen-

TABLA 8.1. *Estructura de una matriz de confusión (clasificación)*

	Referencia						
	Clase 1	*Clase 2*	*Clase 3*	*Clase* n	*Total*	*Exactitud usuario*	*Error comisión*
Clase 1	X_{11}				X_{1+}	X_{11}/X_{1+}	$1-X_{11}/X_{1+}$
Clase 2		X_{22}			X_{2+}	X_{22}/X_{2+}	$1-X_{22}/X_{2+}$
Clase 3			X_{33}		X_{3+}	X_{33}/X_{3+}	$1-X_{33}/X_{3+}$
Clase n				X_{nn}	X_{n+}	X_{nn}/X_{n+}	$1-X_{nn}/X_{n+}$
TOTAL	X_{+1}	X_{+2}	X_{+3}	X_{+n}	ΣX_{ij}		
Exactitud productor	X_{11}/X_{+1}	X_{22}/X_{+2}	X_{33}/X_{+3}	X_{nn}/X_{+n}			
Error omisión	$1-X_{11}/X_{+1}$	$1-X_{22}/X_{+2}$	$1-X_{33}/X_{+3}$	$1-X_{nn}/X_{+n}$			

TABLA 8.2. *Matriz de confusión obtenida para una clasificación no supervisada de una imagen TM e información auxiliar*

Clasificación	*Referencia* 1	2	4	5	6	7	9	A	B	*Total*	*Exactitud usuario*	*Error comisión*
1	551	4		17	12	48	23	128		783	70,4	29,6
2	71	543	190		193	24	75	75		1.171	46,4	53,6
4	57	75	209	3	67	55	145	17		628	33,3	66,7
5	7	3	2	525	49	2	19	9		616	85,2	14,8
6	207	31	57		273	3	5			576	47,4	52,6
7											0,0	100,0
9		116	751	46	107	393	2.507	9		3.929	63,8	37,2
A	255	61	31	1	31	57	84	1.145		1.665	68,7	31,3
B									147	147	100,0	0,0
TOTAL	1.148	833	1.240	592	732	582	2.858	1.383	147	9.515		
Exactitud productor	48,0	65,2	16,9	88,7	37,3	0,0	87,7	82,8	100,0			
Error omisión	52,0	34,8	83,1	11,3	62,7	100,0	12,3	17,2	0,0			

Los números 1 a 9 hacen referencia a modelos de combustible: 1 pastizal; 2 pastizal arbolado; 4 matorral denso y alto; 5 matorral ralo; 6 matorral de altura intermedia; 7 matorral bajo arbolado; 9 cubiertas forestales con sotobosque limpio. La clase A identifica las zonas agrícola-ganaderas y urbanas, y B las láminas de agua.

ciar sobre imágenes Landsat), la difícil discriminación del matorral arbolado (modelo 7, sólo presente en la clasificación de la tabla 8.3), la confusión entre matorral y pastizales y la mezcla entre arbolado y matorral alto-denso.

Si se realizó correctamente la fase de entrenamiento, la mayor parte de estas confusiones ya habrán sido detectadas previamente, pero aquí se ofrece una medición mucho más explícita de estos problemas. A partir de estos datos, puede orientarse la búsqueda de nuevos métodos de clasificación, el empleo de imágenes de otras fechas, o el de bandas auxiliares (modelo digital de elevaciones o suelos), con objeto de facilitar un documento suficientemente certero. Asimismo, puede optarse por una leyenda simplificada, que reduzca las confusiones entre categorías de transición.

TABLA 8.3. *Matriz de confusión para la clasificación mixta con las bandas Landsat-TM e información auxiliar (igual significado que la tabla 8.2)*

Clasificación	*Referencia* 1	2	4	5	6	7	9	A	B	*Total*	*Exactitud usuario*	*Error comisión*
1	927	49	63		42		5	87		1.173	79,0	21,0
2	35	575	74		70	6	34	58		852	67,5	32,5
4	6	7	812		39	104	145			1.113	73,0	27,0
5				590	19		1			610	96,7	3,3
6	11	192	77		489	1	6			776	63,0	37,0
7		2	11			93	51			157	59,2	40,8
9	99	5	181		59	329	2.273			2.946	77,2	22,8
A	70	3	22	2	14	49	343	1.238		1.741	71,1	28,9
B									147	147	100,0	0,0
TOTAL	1.148	833	1.240	592	732	582	2.858	1.383	147	9.515		
Exactitud productor	80,7	69,0	65,5	99,7	66,8	16,0	79,5	89,5	100,0			
Error omisión	19,3	31,0	34,5	0,3	33,2	84,0	20,6	10,5	0,0			

7.2. FIABILIDAD GLOBAL

A partir de la matriz de confusión pueden generarse toda una serie de medidas estadísticas que permitan validar numéricamente los resultados de distintas técnicas de clasificación. La medida más simple consiste en calcular la fiabilidad global del mapa, relacionando los elementos de la diagonal con el total de puntos muestreados:

$$\hat{F} = \frac{\sum_{i=1,n} x_{ii}}{\sum_{i=1,n} \sum_{j=1,n} x_{ij}} \tag{8.7}$$

Para los datos de las tablas 8.2 y 8.3, la fiabilidad estimada sería del 62 y 75 %, respectivamente. Como ya hemos indicado, a partir de este valor estimado en el muestreo puede calcularse el intervalo de confianza donde se situará la fiabilidad real alcanzada por la clasificación. Así, de acuerdo a {8.1}, tendríamos en este caso:

$$F = \hat{F} \pm z \cdot \text{EM} \tag{8.8}$$

El error del muestreo para estas validaciones puede generarse a partir de la fórmula del muestreo aleatorio simple (sin considerar la corrección de poblaciones finitas, que no resulta significativa en este caso):

$$\hat{F} = \frac{\sum_{i=1,n} x_{ii}}{\sum_{i=1,n} \sum_{j=1,n} x_{ij}} \tag{8.9}$$

Para la matriz de la tabla 8.2, por ejemplo, el número de píxeles bien asignados fue 5.900, frente a los 9.515 totales de la muestra. Esto significa una fiabilidad estimada del 62 %. Con un nivel de significación de 0,05 (probabilidad del 95 %), el error del muestreo sería:

$$\text{ES} = \sqrt{\frac{62 \times 38}{9.515}} = 0,497$$

y, por tanto, el intervalo de confianza puede calcularse como:

$$F = 62 \pm 1,96 \times 0,497 = 62 \pm 0,975$$

En definitiva, puede asegurarse, con un 95 % de probabilidad, que la fiabilidad real se encuentra entre 61,025 y 62,975%.

7.3. Fiabilidad del usuario y del productor

Conviene tener en cuenta que la fiabilidad global puede ocultar importantes diferencias entre categorías, que escondan niveles de exactitud muy diversos. Por ello, un análisis más riguroso debe también considerar las celdillas marginales de la matriz. En el caso de las columnas, los marginales indican el número de píxeles que, perteneciendo a una determinada categoría, no fueron incluidos en ella. Éstos se denominan errores de omisión (E_o). Para cada clase se calculan como:

$$E_{o,i} = \frac{X_{+i} - X_{ii}}{X_{+i}} \qquad \{8.10\}$$

donde X_{+i} indica el marginal de la columna i, y X_{ii} la diagonal de dicha columna.

De forma similar, las celdillas no diagonales de las filas expresan los errores de comisión; esto es, píxeles que se incluyeron en una determinada categoría perteneciendo realmente a otra:

$$E_{c,i} = \frac{X_{i+} - X_{ii}}{X_{i+}} \qquad \{8.11\}$$

donde X_{i+} indica el marginal de la fila i, y X_{ii} la diagonal de dicha fila.

Los errores de omisión y comisión expresan dos enfoques del mismo problema. Los primeros se refieren a no asignación a una categoría, mientras los segundos a una delimitación excesivamente amplia. Desde otro punto de vista, algunos autores hablan de exactitud del usuario y del productor (Aronoff, 1982; Story y Congalton, 1986). La primera está en relación inversa con los errores de comisión, mientras la segunda lo está con los de omisión:

$$F_{p,i} = \frac{X_{ii}}{X_{+i}} \qquad \{8.12\}$$

y

$$F_{u,i} = \frac{X_{ii}}{X_{i+}} \qquad \{8.13\}$$

para cada una de las n categorías de la clasificación. El interés de esta distinción puede mostrarse con un sencillo ejemplo. Si para una especie forestal el error de omisión es bajo, existe una alta probabilidad de que la superficie realmente ocupada por esa especie esté incluida en el mapa, lo que significa un logro para el productor del mismo. Sin embargo, puede a la vez haberse producido un alto error de comisión, lo que implica que es muy baja la probabilidad de que una zona clasifi-

cada en el mapa como tal especie lo sea realmente. Esto supone un grave riesgo para el usuario de esa información.

Ambos errores (o, si se prefiere, fiabilidades) están bastante relacionados, pero puede ocurrir que uno sea muy bajo cuando el otro es elevado. El caso más extremo se daría cuando el intérprete hubiera identificado como de un determinado cultivo todo el espacio cultivado en una zona, cuando en realidad existiera una amplia diversidad de cultivos. El error de omisión sería nulo (todo el territorio ocupado por ese cultivo estaría recogido en el mapa), pero el de comisión alto (sólo una pequeña parte de lo que el mapa señala como perteneciente a ese cultivo sería realmente tal).

En el caso de la matriz de confusión recogida en la tabla 8.2, el modelo 9 (arbolado denso) ofrece una fiabilidad del productor del 87,7 %; esto es, aproximadamente nueve de cada diez superficies que tienen realmente esa cubierta están incluidas en la clasificación como tal. Sin embargo, la fiabilidad del usuario supera ligeramente el 60 %, lo que quiere decir que sólo tres quintas partes de las zonas clasificadas como esa cubierta realmente lo son. Aquí el error de omisión es bajo, pero el error de comisión es medio-alto. Ambas medidas son complementarias y de gran trascendencia. La primera desde el punto de vista de quien produce una determinada clasificación, la segunda de la persona que la utiliza.

7.4. El estadístico kappa

Hasta ahora hemos estudiado lo que ocurre en la diagonal y en los residuales de filas y columnas. También resulta de gran interés analizar las relaciones múltiples entre las distintas categorías. Con este objetivo, se introdujeron en los años ochenta algunas técnicas de análisis categórico, idóneas para el estudio global de matrices de confusión.

Uno de los índices más empleados, en este sentido, es el estadístico Kappa (κ), que mide la diferencia entre el acuerdo mapa-realidad observado y el que cabría esperar simplemente por azar. En definitiva, intenta delimitar el grado de ajuste debido sólo a la exactitud de la clasificación, prescindiendo del causado por factores aleatorios. La estimación de κ se obtiene a partir de la siguiente fórmula (Hudson y Ramn, 1987):

$$\hat{\kappa} = \frac{n\sum_{i=1,n} X_{ii} - \sum_{i=i,n} X_{i+}X_{+i}}{n^2 - \sum_{i=i,n} X_{i+}X_{+i}} \qquad \{8.14\}$$

en donde n sería el tamaño de la muestra, X_{ii} el acuerdo observado, y el producto de los marginales (X_{i+}, X_{+i}) el acuerdo esperado en cada categoría **i**. El acuerdo observado aparece en la diagonal de la matriz, mientras el esperado nos sirve para calcular el ajuste entre mapa y realidad que puede deberse al azar. El estadístico κ nos permite conocer si el grado de acuerdo observado se aleja o no significativamente del esperado al azar. En definitiva, este índice pretende evaluar si la clasificación ha discriminado las categorías de interés con precisión significativamente mayor a la que se hubiera obtenido con una asignación aleatoria.

En el caso de las matrices de confusión que venimos analizando, el valor estimado de κ sería de 0,53 (tabla 8.2) y 0,70 (tabla 8.3), lo que indica que las clasificaciones son entre un 53 y un 70 % mejores de lo esperable al azar, respectivamente. Un valor de κ igual a 1 indica un acuerdo pleno entre la realidad y el mapa, mientras un valor cercano a 0 sugiere que el acuerdo observado es puramente debido al azar. Por su parte un valor negativo, supone también una clasificación pobre, si bien su sentido depende de otros factores externos, como el propio tamaño de la muestra.

Conviene indicar que el estadístico κ también puede calcularse para una determinada categoría de interés (es el denominado κ condicional), o se puede ponderar en función de algún criterio definido por el usuario. Como es lógico, no todas las confusiones son igualmente transcendentales. Por ejemplo, no es lo mismo que la confusión se produzca entre matorral y matorral-arbolado, que entre matorral y cultivos. En consecuencia, podemos obtener un valor ponderado de κ, a partir de unos pesos (w_{ij}) que asigne el usuario en función de la gravedad que estime se produce cuando se confunden las categorías i y j. El nuevo valor de κ sería:

$$\hat{\kappa} = \frac{\sum_{i=1,n} X_{ii} / n - \sum_{i=i,n} w_{ij} X_{i+} X_{+i} / n}{1 - \sum_{i=i,n} w_{ij} X_{i+} X_{+i} / n} \quad \{8.15\}$$

Una de las aplicaciones más claras del índice κ es comparar clasificaciones realizadas por distintos métodos, con objeto de estudiar si difieren significativamente en cuanto a su grado de ajuste con la realidad (Fitzegarld y Lees, 1994). Para ello, puede utilizarse la distribución normal para estimar intervalos de confianza (Skidmore, 1989):

$$z = \frac{|\hat{\kappa}_1 - \hat{\kappa}_2|}{\sqrt{\sigma^2_{\kappa 1} + \sigma^2_{\kappa 2}}} \quad \{8.16\}$$

El cálculo de la varianza de Î puede realizarse a partir de la siguiente fórmula (Congalton y Green, 1999):

$$\sigma^2_{\kappa} = \left(\frac{1}{n}\right)\left\{\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4}\right\} \quad \{8.17\}$$

donde θ_1, θ_2, θ_3, y θ_4 se calculan de la forma siguiente:

$$\theta_1 = \left(\frac{1}{n}\right)\sum_{1=1,n} X_{ii} \quad \{8.18\}$$

$$\theta_2 = \left(\frac{1}{n^2}\right)\sum_{1=1,n} X_{i+} X_{+i} \quad \{8.19\}$$

$$\theta_3 = \left(\frac{1}{n^2}\right)\sum_{1=1,n} X_{ii}(X_{i+} + X_{+i}) \qquad \{8.20\}$$

$$\theta_4 = \left(\frac{1}{n^3}\right)\sum_{1=1,n}\sum_{j=1,n} X_{ij}(X_{j+} + X_{+i})^2 \qquad \{8.21\}$$

Este test puede emplearse para contrastar la validez efectiva de distintos métodos de clasificación (Chuvieco y Congalton, 1988; Fitzegarld y Lees, 1994). En el caso de los dos métodos de clasificación que venimos comentando en este capítulo (tabla 8.2 y 8.3), los valores estimados de κ son 0,53 y 0,70, respectivamente, y los valores de varianza calculados son, respectivamente, de 0,000034 y 0,0000282. Por tanto, el valor z resultante de aplicar {8.16} sería 20,40. Este valor excede con creces el que cabría esperar aleatoriamente para un 95 % de probabilidad (el umbral sería 1,96). Puede concluirse, por tanto, que ambas clasificaciones son significativamente distintas, o, dicho de otra forma, que la segunda es significativamente mejor que la primera.

Stehman (1999*a*) propone otros métodos para comparar dos clasificaciones de la misma o distintas zonas, utilizando la misma o distinta leyenda temática. Los métodos se basan en los valores de fiabilidad del usuario o en el conjunto de la matriz de confusión. Contempla la posibilidad de ponderar las categorías de partida, pero no incluye test de significación para validar si son estadísticamente distintas las diferencias encontradas. Sugiere, finalmente, que el estadístico κ no resulta apropiado para las comparaciones al descartar el margen de aleatoriedad, que también puede incluir clasificaciones correctas, por lo que propone modificar ese estadístico considerando el número de categorías que se estén considerando.

7.5. Normalización de la matriz de confusión

En el caso de que se pretenda comparar dos matrices de confusión —ya sea generadas a partir de distintos métodos de asignación, ya de distintas imágenes o de distintos individuos— κ puede indicarnos cual de ellos es más efectivo en su conjunto. Ahora bien, en el caso de que se intente comparar la fiabilidad de dos mapas con distinto tamaño de muestreo, el estadístico κ no nos ofrece una valoración adecuada. Con vistas a solucionar este problema, Congalton (1984) propuso aplicar un procedimiento multivariado para normalizar una matriz cuadrada (Bishop *et al.*, 1975). Se trata de un método iterativo que ajusta los totales de filas y columnas a un valor común (+1), mediante sucesivos incrementos o reducciones en las celdillas de la matriz. El proceso se detiene cuando los marginales de cada fila y columna sumen + 1,00, o un valor muy próximo a éste. En las tablas 8.4 y 8.5 se presentan las matrices normalizadas que venimos analizando, gracias a un programa cedido por el Prof. Congalton.

Este proceso ofrece una nueva medida de la fiabilidad global. Basta calcular el valor medio de los elementos de la diagonal, que siguen indicando el acuerdo entre filas y columnas. Obviamente la situación ideal sería que todos los elementos diagonales de la matriz fueran igual a 1. Esto indicaría un acuerdo perfecto entre realidad y mapa, mientras una pobre clasificación se mostraría en valores diagonales muy bajos.

TABLA 8.4. *Normalización de la matriz correspondiente a la tabla 8.2*

Clasificación	*Referencia*								
	1	*2*	*4*	*5*	*6*	*7*	*9*	*A*	*B*
1	0,528	0,010	0,001	0,029	0,021	0,194	0,038	0,180	0,000
2	0,030	0,527	0,166	0,000	0,137	0,042	0,052	0,046	0,000
4	0,044	0,137	0,340	0,005	0,089	0,179	0,187	0,020	0,000
5	0,007	0,008	0,005	0,847	0,080	0,010	0,030	0,013	0,000
6	0,231	0,082	0,135	0,001	0,523	0,016	0,010	0,001	0,001
7	0,058	0,137	0,123	0,101	0,100	0,244	0,097	0,085	0,054
9	0,000	0,034	0,199	0,010	0,023	0,207	0,525	0,002	0,000
A	0,099	0,056	0,026	0,001	0,021	0,093	0,055	0,649	0,000
B	0,003	0,008	0,007	0,006	0,006	0,014	0,006	0,005	0,944

En este caso, el valor medio de las diagonales ofrece un porcentaje medio de fiabilidad entre el 57 y el 78 %. Por categorías, se matizan más los valores aportados por las tablas originales, especialmente en lo que se refiere a acuerdos estimados perfectos, como es el caso de las áreas agrícolas que pasan del 100 % de exactitud a valores cercanos a 0,94.

Conviene tener en cuenta que estas medidas representan una estimación baja de la fiabilidad real, debido a las propias características del proceso de normalización. Es preciso considerar que la matriz de confusión es un caso muy peculiar de una tabla de contingencia, por cuanto aparecen con frecuencia celdillas con valores muy bajos o iguales a cero, ya que hay confusiones entre categorías muy poco probables. Como quiera que el proceso de normalización añade una pequeña cantidad a cada celdilla para evitar los ceros, las celdillas que expresan aciertos se ven infravaloradas frente al resto. Este es el caso del modelo combustible 5, con una fiabilidad del 99,7 % en la tabla original (ensayo de clasificación mixta), que desciende a 97 % en la normalizada, como consecuencia del reducido tamaño de la muestra.

Pese a este problema, el proceso de normalización ofrece una visión complementaria a la recogida en la matriz original. Su medida de la fiabilidad global y para cada una de las categorías, puede considerarse, con las reservas apuntadas, como

TABLA 8.5. *Normalización de la matriz correspondiente a la tabla 8.3*

Clasificación	*Referencia*								
	1	*2*	*4*	*5*	*6*	*7*	*9*	*A*	*B*
1	0,804	0,040	0,031	0,001	0,042	0,000	0,002	0,080	0,001
2	0,046	0,692	0,054	0,001	0,103	0,006	0,016	0,080	0,001
4	0,010	0,011	0,708	0,002	0,069	0,115	0,083	0,001	0,001
5	0,000	0,000	0,000	0,978	0,019	0,000	0,001	0,001	0,001
6	0,015	0,225	0,055	0,001	0,698	0,001	0,003	0,001	0,001
7	0,005	0,024	0,066	0,010	0,006	0,680	0,194	0,005	0,009
9	0,074	0,004	0,076	0,001	0,050	0,174	0,621	0,000	0,001
A	0,045	0,002	0,008	0,003	0,010	0,022	0,080	0,830	0,001
B	0,002	0,002	0,001	0,004	0,002	0,001	0,001	0,002	0,986

TABLA 8.6. *Comparación de los índices de verificación para varias clasificaciones digitales de la zona de Gredos (valores porcentuales: Salas y Chuvieco, 1995)*

Clasificación	*Fiabilidad global*	*Índice κ*	*Fiabilidad normalizada*
No supervisada (TM + información auxiliar)	62	53	57
No supervisada (TM)	60	50	56
Supervisada	62	54	60
Mixta	75	70	78

una interesante alternativa a los métodos tradicionales, permitiendo comparar matrices con distinto número de muestras.

En la tabla 8.6 se recoge un resumen de los valores de fiabilidad, según los criterios expuestos en este capítulo, para las distintas matrices analizadas.

7.6. VALIDACIÓN PARA CLASES BINARIAS

Para el caso concreto de trabajar con una variable dicotómica (quemado-no quemado; nubes-despejado; agua-tierra...) pueden plantearse otros criterios de validación, que facilitan una visión complementaria a los previamente analizados.

En este caso, el mapa resultado tendría únicamente dos categorías, por lo que podría resolverse el análisis con una tabla de confusión simple, con cuatro cruces posibles (sí en ambas, no en ambas, si-no y no-si). En esa matriz de confusión, además de los desajustes entre la imagen clasificada y el documento de referencia, también pueden encontrarse problemas debidos a la distinta resolución espacial de las dos fuentes. Este sería el caso cuando se verifica una cartografía de áreas quemadas o de puntos de calor realizada sobre imágenes de baja resolución espacial a partir de imágenes de alta o media resolución (Boschetti *et al.*, 2006; Morisette *et al.*, 2005). La clasificación puede haber sido correcta, pero la diferente superficie abarcada en los dos tipos de imágenes tiende inevitablemente a crear desacuerdos entre ellos (fig. 8.11), que no son necesariamente errores, sino más bien defectos debidos a la generalización que implica el diferente tamaño de píxel.

En consecuencia, puede utilizarse como criterio de validación alternativo dividir el área en celdas de un tamaño 5 o 10 veces superior a la resolución del píxel de baja resolución, y calcular para cada una de ellas la proporción de superficie ocupada por la clase a validar. Eso permitirá construir un gráfico de dispersión, que muestre las coincidencias espaciales entre los dos documentos (Roy *et al.*, 2005). Si la regresión entre ellas pasa por el origen y tiene una pendiente cercana a uno, esto implicaría que ambos documentos (baja y alta resolución) estiman de modo similar la variable de interés. En la figura 8.12 se incluye ejemplos de este tipo de análisis, mostrando la proporción de área quemada mediante imágenes MODIS y Landsat-TM en dos áreas situada en el norte y centro de Sudamérica. El trabajo corresponde a la validación que se realizó para una cartografía de áreas quemadas de Latinoamérica en el marco de las actividades de la RedLatif (Chuvieco *et al.*, 2008*c*).

		Landsat	
		Q	N - Q
MODIS	Q	A	B
	N - Q	C	D

Q: Quemado
NQ: No quemado

Comisión Q: 1 - (A/(A + B)) = B/(A + B)

Omisión Q: 1 - (A/(A + C)) = C/(A + C)

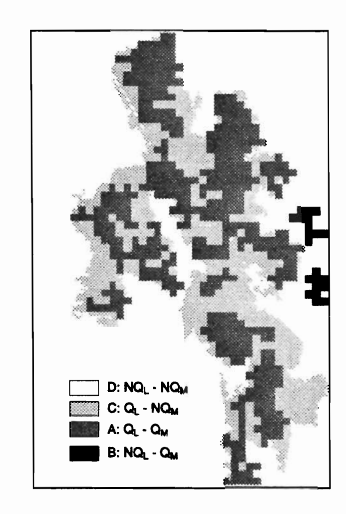


FIG. 8.11. *Validación para una clasificación dicotómica: área quemada con imágenes de baja y alta resolución.*

FIG. 8.12. *Validación cruzada y diagrama de dispersión entre proporciones de área quemada para dos escenas Landsat en el este de Colombia (a) y este de Bolivia (b).*

8. Verificación de análisis multitemporales

En el capítulo anterior consideramos el interés de los estudios de detección de cambios en teledetección. Lógicamente, ese tipo de estudios también requiere validar posteriormente los resultados. En este caso, se trataría de ver la fiabilidad alcanzada por una interpretación de dos fechas simultáneamente, lo que implica considerar la fiabilidad de cada fecha por separado y de las dos en conjunto. Esto complica notablemente el análisis de las matrices de confusión, ya que a los factores de ruido potencial antes comentado le añadimos la propia incertidumbre del ajuste entre fechas y la dificultad de obtener información de referencia para períodos a veces muy separados en el tiempo.

Sintetizando estos aspectos, podemos señalar como principales novedades de la verificación cuando se aplica a estudios de detección de cambios las siguientes (Fernández-Gustiz, 2001):

— Aumento del número de categorías en la matriz de error. El número potencial de categorías («estable», «de», y «a») para dos fechas es el cuadrado del número de categorías en una única fecha o imagen. Todas estas clases deben de ser consideradas en la evaluación del error, por lo que finalmente la matriz de confusión tendrá n^4 celdillas, siendo n el número de clases de partida para una fecha (tabla 8.7).

— Mayor complejidad en el esquema de muestreo, al aumentar mucho el número de categorías a verificar. Puesto que, además, será frecuente que algunos de los potenciales cambios sean muy infrecuentes o imposibles (por ejemplo, de áreas urbanas a láminas de agua), tendremos que aumentar notablemente el tamaño de la muestra para poder verificar esos cruces. En estas ocasiones, el muestreo estratificado o el basado en información auxiliar puede ser una buena alternativa (Biging *et al.*, 1998).

— Dificultad para obtener la información de referencia en fechas pasadas. Como es lógico, en la mayor parte de los casos, no tendremos información de deta-

TABLA 8.7. *Matriz de confusión para la detección de cambios*

			Referencia								
			Estable			*Cambio*					
			AB	*BB*	*CC*	*AB*	*AC*	*BA*	*BC*	*CA*	*CB*
Clasificación	*Estable*	AA	1	3	3	5	5	5	5	5	5
		BB	3	1	3	5	5	5	5	5	5
		CC	3	3	1	5	5	5	5	5	5
	Cambio	AB	4	4	4	2	6	6	6	6	6
		AC	4	4	4	6	2	6	6	6	6
		BA	4	4	4	6	6	2	6	6	6
		BC	4	4	4	6	6	6	2	6	6
		CA	4	4	4	6	6	6	6	2	6
		CB	4	4	4	6	6	6	6	6	2

A, B, C son distintas categorías temáticas. Ver texto para explicación. Adaptado de Congalton y Green (1999) y Biging *et al.* (1998).

lle de las coberturas terrestres para una fecha distante, tal vez varios años, de la actualidad. Fotografías aéreas o documentos cartográficos de fecha similar a la que pretende emplearse, pueden paliar este problema, aunque, como ya hemos indicado, no siempre resultan plenamente fiables.

Cuando se pretende verificar una detección de cambios, la matriz de confusión se complica notablemente. Para un sencillo ejemplo de tres categorías en las dos fechas, tendríamos 9 categorías de posible dinámica (los posibles cruces entre las dos fechas), y por tanto la matriz de confusión contaría con 81 celdas (las nueve posibilidades reales cruzadas con las 9 posibles asignadas por la interpretación de la imagen). En esa matriz de confusión multitemporal se incluiría la verificación tanto de las clases estables, aquellas en donde se haya mantenido la misma categoría entre fechas, como de las clases dinámicas. Todas esas posibilidades requieren validación. Por tanto, la matriz de confusión incluirá la tabulación de píxeles que nuestro mapa de cambios señala como «de clase *X* a clase *Y*», mientras en la realidad son ése u otro tipo de transiciones. Como en el caso de la matriz de confusión simple, en la diagonal se incluirán las detecciones de cambio correctas (cuando se detectó como estable o como un cierto cambio cuando en realidad así era), y fuera de la diagonal los cambios erróneos (detectar como estable cuando era cambio, o viceversa, o detectar un cambio entre dos categorías, cuando en realidad se produjo entre otras).

Siendo un poco más específicos, podemos explicar mejor la estructura de una matriz de confusión multitemporal utilizando la notación de Biging et al. (1998), que recoge la tabla 8.7. Las celdillas anotadas con 1 indicarían áreas detectadas como estables, cuando ciertamente lo son, mientras que las que tienen un 2 señalarían áreas correctamente clasificadas como de un determinado cambio. La suma de ambos, 1 y 2, indicaría la fiabilidad global de la detección de cambios efectuada por el intérprete. El resto suponen errores, que vendrían definidos por varias posibilidades: el 3 señala las zonas señaladas como estables pero en una categoría que no les corresponde; el 4 identifica sectores en donde se señalaron cambios cuando en realidad se mantuvo la misma categoría (se trata, por tanto, de errores de comisión, al identificar como cambio lo que no fue tal); el 5 determina cambios reales no discriminados (por tanto, errores de omisión), y el 6 cambios incorrectamente identificados (se detectan como cambios, pero no en la categoría correcta, lo que implica error de omisión o de comisión, dependiendo de la clase que consideremos).

Las medidas de fiabilidad global y por categorías son las mismas, por otro lado, que las señaladas para la matriz unitemporal.

CAPÍTULO 9

TELEDETECCIÓN Y SISTEMAS DE INFORMACIÓN GEOGRÁFICA

«Detrás de la máscara de la libertad se esconde frecuentemente la dejadez, el deseo de no implicarse.»

SUSANA TAMARO, *Donde el corazón te lleve*

1. **Necesidad de los SIG**

Buena parte de los usuarios de la teledetección espacial tienen como objetivo último de su trabajo integrar la información resultante con otras variables geográficas, de cara a obtener una visión más sintética de las características de un determinado territorio. Este enfoque resulta de gran interés de cara, por ejemplo, a una evaluación más completa de los recursos que nos brinda ese espacio, o a abordar una planificación más acorde con sus potencialidades. En cualquier caso, frecuentemente los resultados de la interpretación de las imágenes no suponen la culminación del trabajo, sino más bien una fase en la recopilación de información sobre el área de interés, por lo que resulta preciso conectar esos resultados con otras variables territoriales.

Este tipo de enfoques se ha visto notablemente favorecido por el desarrollo de los Sistemas de Información Geográfica (SIG, o, en la terminología anglosajona *Geographic Information Systems, GIS*). Los SIG pueden definirse como programas que almacenan, gestionan, manipulan y representan gráficamente datos con algún tipo de componente espacial (Bosque, 1997; Burrough y McDonell, 1998; Cebrián, 1988). Esto significa que la información que albergan está referenciada geográficamente, ya se trate de mapas, estadísticas o datos climáticos sobre un territorio concreto, por lo que todas estas variables pueden relacionarse mutuamente de formas muy diversas (fig. 9.1). Por cuanto la información que contienen se almacena en formato digital, los SIG facilitan múltiples operaciones que resultan difícilmente accesibles por medios convencionales: generalización cartográfica, integración de variables espaciales, modelado del relieve, análisis de vecindad, etc. Además, los SIG permiten almacenar esa información espacial de forma eficiente, simplificando su actualización y acceso directo al usuario. En definitiva, amplían enormemente las posibili-

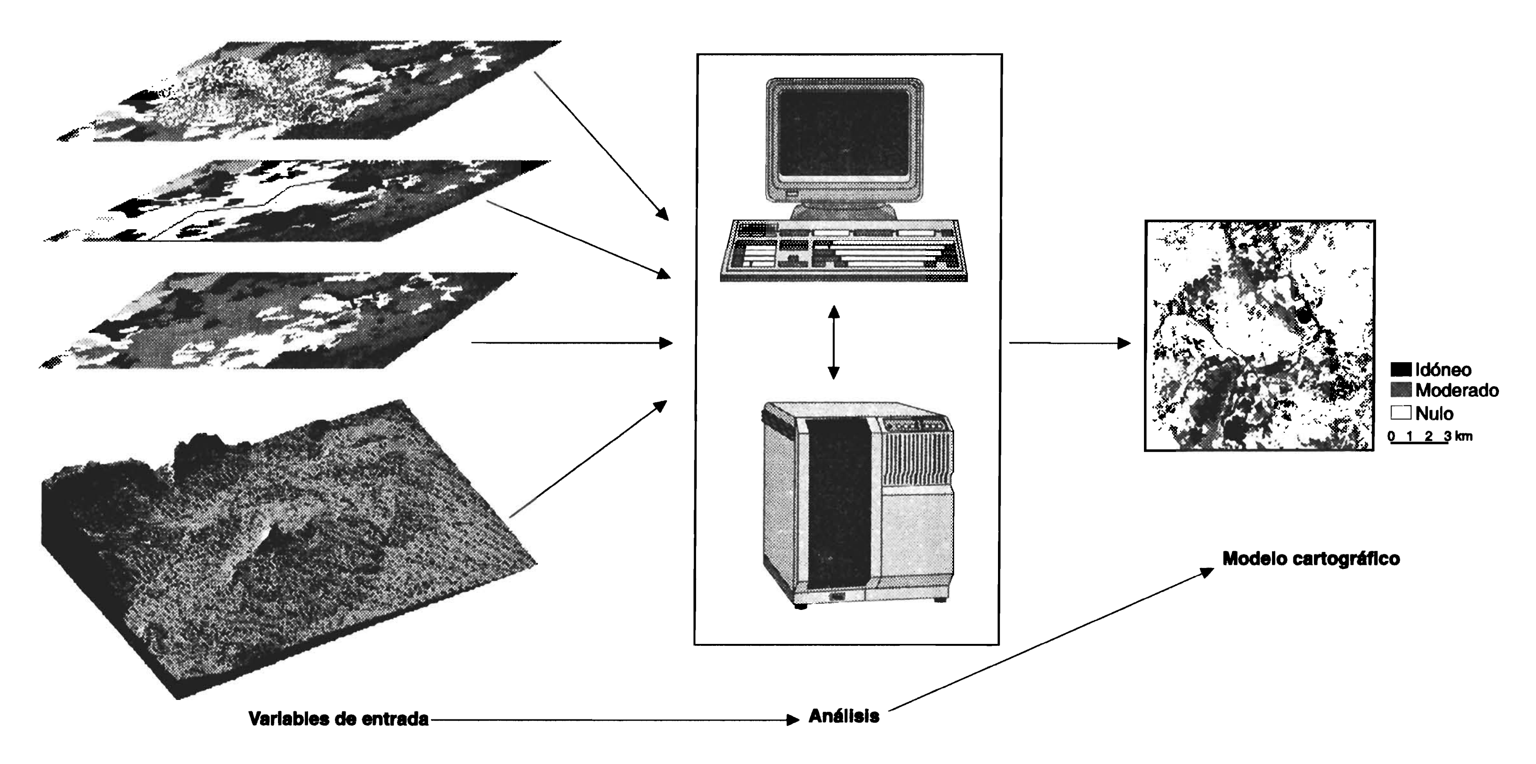


FIG. 9.1. *Flujo de información en un Sistema de Información Geográfica.*

dades de análisis que brindan los mapas convencionales, además de mejorar su almacenamiento y visualización.

Un SIG está compuesto por unos equipos físicos, especializados en el manejo de información espacial, y una serie de programas que, conectados con aquéllos, permiten realizar múltiples transformaciones a partir de las variables espaciales introducidas al sistema. El SIG no es un producto cerrado en sí, sino un compuesto de elementos diversos: ordenador, digitizador, trazador gráfico, impresoras, y distintos paquetes de programas, orientado hacia una finalidad específica. También existen SIG comerciales, que intentan recoger todos estos productos bajo una misma estructura, si bien lo más habitual sea la comercialización exclusiva de los programas, que pueden adaptarse a soportes físicos muy variados.

La amplia disponibilidad de manuales sobre SIG (Aronoff, 1989; Bosque, 1997; Burrough y McDonell, 1998; Comas y Ruiz, 1993; Gomez-Delgado y Barredo-Cano, 2006; Gutiérrez y Gould, 1994; Juppenlatz y Tian, 1996; Maguire *et al.*, 1991; Moreno, 2005; Tomlin, 1990) nos aconseja prescindir de comentarios sobre los componentes y principales funciones de un SIG, que dejamos al lector interesado para su consulta. En consecuencia, nos centraremos con mayor atención sobre las relaciones entre los SIG y la teledetección, así como sobre las modalidades concretas a través de las cuales ambas pueden integrarse.

2. **Paralelismo y convergencia**

Podemos afirmar que los orígenes de la teledetección y los SIG siguieron una trayectoria bastante paralela. En otras palabras, ambas técnicas surgieron como disciplinas independientes, sólo unidas por su orientación medioambiental. El primer SIG, diseñado en Canadá en los años sesenta, pretendía facilitar la labor de conservación de los ingentes recursos de que dispone ese país. Sin embargo, se dirigía más hacia el análisis que hacia la recogida de información espacial, que se suponía disponible por otras fuentes convencionales. Esta dimensión cartográfica de los SIG se refuerza en los años setenta, especialmente a través del trabajo del *Laboratory for Computer Graphics* de la Universidad de Harvard, que pretendía resolver los problemas de geometría computacional implicados en el proceso de esta información cartográfica (Coppock y Rhind, 1991).

Por otro lado, la teledetección durante los años sesenta se convirtió en una fuente más de información medioambiental, considerada en sí misma y no tanto en su conexión con otras variables espaciales. Se pretendía facilitar una cartografía e inventario de algún fenómeno de interés, culminando el trabajo con la obtención de dichos productos. Ahora bien, el propio desarrollo de las técnicas de interpretación, especialmente a partir de 1972 cuando se comienzan a difundir las primeras imágenes Landsat, amplió ese planteamiento. En un primer momento, la relación entre ambas técnicas se centró en acudir a variables cartográficas para complementar a la clasificación digital de las imágenes (Strahler *et al.*, 1978). Un paso más allá vino dado, a inicios de los años ochenta, cuando comienza a considerarse la teledetección como auxiliar de un SIG, sirviendo como una fuente más de información para un estudio integrado sobre el territorio.

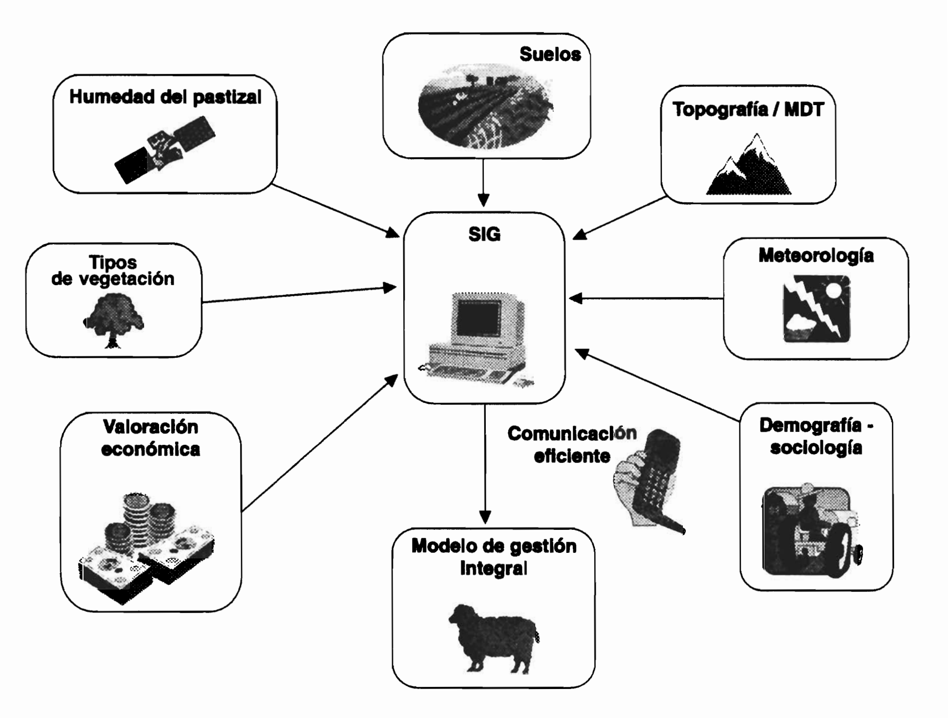


FIG. 9.2. *Modelo de gestión de la información espacial para una evaluación agrícola.*

Esta situación se ha mantenido hasta la actualidad, constituyéndose los SIG como elementos protagonistas del análisis espacial, al integrar la información geográfica, sea cual sea la procedencia (fig. 9.2). En este sentido, la teledetección podría considerarse como una fuente más de información para un SIG, junto a otras más convencionales (cartografía analógica, datos censales, sistemas de captura de datos, etc.) o recientes (Sistemas de Posicionamiento Global, GPS, sensores terrestres de adquisición de datos, etc.). Al ser necesario superar algunos escollos en la manipulación de datos tan diversos, que no se contemplaron inicialmente en el diseño de los SIG (volumen de almacenamiento, estructuras de datos, herramientas de análisis), algunos autores son partidarios de acuñar nuevos términos como sería el de Sistemas Integrados de Información Geográfica (*Integrated Geographic Information System, IGIS*: Davis y Simonett, 1991), para designar a estos nuevos SIG.

La creciente convergencia entre la teledetección y los SIG se justifica, entre otras, por las siguientes razones:

1. Ambas poseen una clara orientación territorial.
2. Cuentan con similares requerimientos, tanto en *hardware* como en *software*.
3. Se desarrollan por y para el mismo tipo de profesionales.
4. Responden a demandas de investigación similares, como es el caso del análisis de errores, la estructura y acceso a los datos, el desarrollo del entorno informático y la metodología de interpretación (Star *et al.*, 1991).

La integración tampoco está exenta de problemas, ligados a la disponibilidad de datos (costes, nivel de resolución espacial, espectral y temporal), a la educación y al acceso a los equipos, entre otros (Lauer *et al.*, 1991). No obstante, en los últimos años, parece confirmarse una tendencia hacia la convergencia entre ambas técnicas.

3. Requisitos técnicos comunes

Tanto los SIG como la teledetección (si se aborda una interpretación digital de los datos) requieren unos equipos físicos especializados en el manejo de información espacial, así como una serie de programas que, conectados con aquellos, permitan realizar múltiples transformaciones de datos. Los componentes que requiere la interpretación digital de imágenes son, en gran medida, comunes a los que requieren los programas SIG. La distinción principal atañe no tanto a la teledetección y los SIG, sino más bien a los SIG basados sobre formatos ráster frente a los basados en formatos vectoriales. Los primeros tienen una gran afinidad con el tratamiento digital de imágenes, ya que la estructura de datos es muy similar. Por el contrario, los SIG vectoriales manejan la información con características muy distintas, aunque en ocasiones esos procesos sean opacos al usuario, por lo que requieren unidades de entrada peculiares (digitalizador), que apenas tienen importancia en el tratamiento digital de imágenes.

Respecto al *software*, las relaciones con la teledetección también son muy diferentes si se trata de SIG ráster o vectoriales. Ambos cuentan con procesos muy similares a los aplicados en teledetección: visualización, correcciones geométricas, superposición de capas, operaciones aritméticas o filtrajes. Ahora bien, la forma concreta de resolver estos procesos es muy distinta en ambas estructuras de almacenamiento. Una transformación de mapas en un SIG vectorial implica resolver una serie de problemas geométricos bastante complejos, ya que precisa una definición topológica de cada una de las transformaciones (Bosque, 1997; Burrough y McDonell, 1998). Por su parte, la estructura ráster está muy cercana a la de una imagen digital, con la sola variante de que ésta presenta una escala de intervalo (es una variable cuantitativa, con una escala comprendida entre 0 y 2^n, siendo n el número de bits de la resolución radiométrica del sensor), mientras las almacenadas en un SIG son con frecuencia nominales (corresponden a información categorizada: tipos de suelo o vegetación, por ejemplo). Esto explica que algunos procesos sean específicos de cada técnica. Los filtros modales, las operaciones lógicas o los análisis de proximidad, exigen una categorización previa de la información. mientras los realces del contraste, filtros, índices de vegetación, análisis de componentes principales o clasificación numérica sólo tienen sentido cuando se trata de variables medidas en una escala numérica continua (ND, valores de radiancia, temperatura o reflectividad de la imagen). Lógicamente, cuando en el SIG se analicen variables cuantitativas (precipitación, temperatura, altitud, pendiente, etc.) también pueden aplicarse este tipo de técnicas de transformación digital.

4. Los SIG como apoyo a la teledetección

A lo largo de esta obra hemos visto en diversos capítulos la importancia de contar con información auxiliar para corregir algunos errores incluidos en las imágenes, así como para refinar la clasificación de diversas categorías. Modelos digitales de elevación (MDE), mapas de suelos o climáticos, límites administrativos, regiones ecológicas o parcelas catastrales son ejemplos de variables cartográficas que pueden enriquecer notablemente el análisis digital de las imágenes.

Lo más común en los últimos años es que esta información auxiliar provenga de un SIG, cuyos datos estén previamente georreferenciados a las imágenes o viceversa, mediante los oportunos procesos de corrección. Esa información no espectral puede incorporarse al tratamiento de las imágenes en varias fases: antes, durante y después de la clasificación.

Algunos ejemplos de cómo pueden emplearse los SIG antes de la clasificación serían la incorporación de un MDE en sectores de topografía accidentada, de cara a refinar la corrección geométrica y radiométrica de las imágenes, paliando la distorsión en ellas incluida por el relieve, o la estratificación de la imagen a partir de regiones bioclimáticas, con objeto de clasificar digitalmente áreas más similares, evitando la excesiva dispersión que puede presentarse en algunas categorías (Strahler, 1981).

Durante la clasificación, los datos auxiliares pueden ser de gran ayuda en la correcta delimitación de los campos de entrenamiento —si se opta por la clasificación supervisada—, o en el reconocimiento temático de los grupos espectrales (*clusters*), caso de emplear la no supervisada. Ya hemos indicado que buena parte de la calidad de los resultados de la clasificación depende de delimitar apropiadamente las áreas de entrenamiento, por lo que cualquier información auxiliar que ayude a su mejor selección será de gran utilidad. Si, por el contrario, se opta por la clasificación no supervisada, la información almacenada en un SIG también resulta muy útil, por ejemplo de cara a etiquetar los grupos espectrales definidos por el ordenador (Loveland *et al.*, 2000).

Las variables auxiliares también pueden emplearse como nuevas bandas para la clasificación, aportando una dimensión no-espectral para la discriminación de determinadas clases (Riaño *et al.*, 2002*a*). Éste sería el caso de incluir mapas de pendientes o precipitación. En los clasificadores convencionales solo pueden incorporarse variables cuantitativas, mientras las cualitativas, como suelos o regiones biogeográficas, sería más apropiadas para clasificadores en árbol.

En la fase posterior a la clasificación, los SIG pueden emplearse para verificar las clasificaciones. La información almacenada en estos sistemas puede facilitar la localización de los campos de verificación, de cara a valorar cuantitativamente la precisión alcanzada en la clasificación. Además, las variables auxiliares pueden servir para reasignar algunas categorías, en caso de que no hayan sido discriminadas sólo a partir de información espectral (Hutchinson, 1982). Por ejemplo, algunos cultivos o especies forestales, que contaran con similar comportamiento espectral, podrían discriminarse gracias al tipo de suelos o pendientes sobre los que se asientan. De esta forma, bastaría contar con esa variable auxiliar, suelo, para que la identificación fuera mucho más certera. Otro aspecto de gran interés hace referencia al error de frontera, que ya comentamos en el anterior capítulo, y aparece con frecuencia en áreas de transición en donde la definición de un píxel puede resultar ambigua, ya

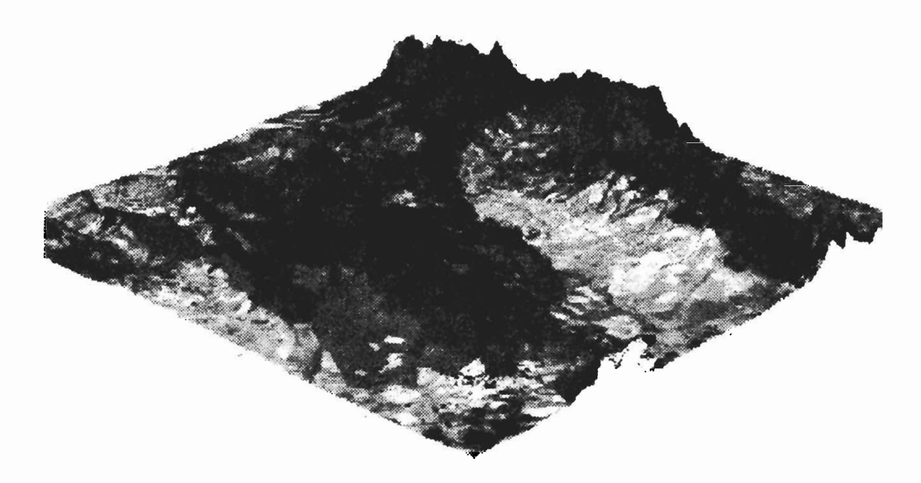


FIG. 9.3. *Vista tridimensional del P.N. Cabañeros construida a partir de una imagen Landsat-TM y un modelo digital de elevación.*

que, de hecho, corresponde a la respuesta espectral de dos o más cubiertas distintas. Un procedimiento para reducir la influencia de este error sería incluir, desde un SIG, los bordes que definen las distintas parcelas, modificando la pertenencia de los píxeles situados en esos límites.

Un último tema en donde la información de un SIG facilita un valor añadido a la teledetección hace referencia a la visualización de resultados. La integración de la teledetección y los SIG, permite ampliar notablemente las posibilidades gráficas de la cartografía convencional, facilitando su análisis visual al público profano. Algunas experiencias en esta línea son la realización de perspectivas tri-dimensionales o vuelos simulados, a partir de una imagen original o clasificada y de un modelo digital de elevación (fig. 9.3).

5. La teledetección como fuente de datos para un SIG

5.1. EL ACCESO A LA INFORMACIÓN GEOGRÁFICA

Entre los siglas que definen a los SIG, a nuestro juicio resulta evidente que la más importante es la central, esto es la I de Información, puesto que el término Geográfica no es más que un calificativo de ésta, y el de Sistemas puede aplicarse a otras muchas aplicaciones informáticas. Los SIG son básicamente herramientas para la mejor gestión de la información disponible sobre el territorio: no permiten por sí solos generarla. En consecuencia, si la información almacenada en un SIG no es suficientemente fiable, está anticuada o es incompleta, de nada sirve contar con un soporte físico o lógico muy poderoso, pues ese SIG será de poco provecho en la solución de los problemas reales que afectan a las personas de un determinado territorio. Los SIG sin información de suficiente calidad son únicamente fuegos artificiales, vistosos pero inútiles.

En definitiva, resulta imprescindible que las capas de información que integran

un determinado SIG (litología, relieve, suelos, datos climáticos, vegetación, cultivos, datos censales, etc.), tengan la resolución y el nivel de fiabilidad adecuado, y estén debidamente actualizadas. Puesto que esas variables son comúnmente generadas por distintas agencias, que, a su vez, pueden haber contratado el trabajo a múltiples intérpretes, la integración de esas variables en el SIG puede ser muy compleja, tanto desde el punto de vista temático como geométrico (Mounsey, 1991). En consecuencia, no sólo es necesario que exista una buena información geográfica, sino también que pueda integrarse en una base de datos coherente (Martínez *et al.*, 2008). Esto implica coordinación, tanto entre los diversos grupos que han generado cada variable (en el seno de una institución), como también entre las distintas instituciones con responsabilidades cartográficas.

Con mucha frecuencia, ambos aspectos no se garantizan adecuadamente, lo que dificulta considerablemente la operatividad de un SIG. Por un lado, pueden faltar determinados inventarios cartográficos, tan vitales para la planificación física, como son la cartografía de suelos o geomorfológica. Por otro, pueden presentarse desconexiones entre los organismos que generan la información. Esto implica, en muchas ocasiones, duplicar esfuerzos y presupuestos, ya sea porque la información generada por estos organismos no resulte intercambiable, porque no se han arbitrado canales apropiados para la distribución pública de esa información, o, simplemente, porque no se conoce.

La teledetección espacial, por sí sola, no puede resolver estos problemas, pero puede contribuir a paliarlos al facilitar datos de libre adquisición, en formatos estándar, y plenamente actualizados. Comprendiendo el alto coste de generar información geográfica de calidad, la inversión en imágenes de satélite puede justificarse plenamente, sin olvidar que en muchas ocasiones lo verdaderamente caro es no disponer de la información necesaria para tomar decisiones cuando resulta imprescindible hacerlo (en situaciones de emergencia, por ejemplo: Camarasa *et al.*, 2001).

Existen diversos medios para generar información geográfica, desde el tradicional trabajo de campo (insustituible todavía en muchas ocasiones), hasta los sensores terrestres (medidores de temperatura, humedad o polución atmosférica, estaciones de aforo, etc.), sistemas de posicionamiento global (GPS) y teledetección aérea o espacial. Todos ellos son medios necesarios, que convendrá seleccionar en función de la variable que quiera obtenerse y de los propios requisitos del trabajo (presupuesto, tiempo de obtención, fiabilidad requerida, etc.). Sintetizando las cosas, las ventajas de la teledetección como fuente de datos para un SIG se centran principalmente en la obtención de algunas variables de interés (fase de inventario cartográfico), y en la actualización de información ya generada. A continuación analizamos con más detalle ambos aspectos.

5.2. Fase de inventario

La teledetección, como hemos visto en capítulos precedentes, puede resultar una herramienta idónea para cartografiar determinadas variables: temperatura del agua del mar, contenido en clorofila, cobertura de nieve, rendimientos del cultivo, ocupación del suelo, etc., y la lista se está continuamente ampliando ante la dispo-

nibilidad de nuevos sensores, con mayor resolución espacial, espectral o temporal (Baker, 2001). En algunos casos, estas aplicaciones abarcan campos ya recogidos por otros métodos más tradicionales, como la fotografía aérea o los trabajos de campo. El empleo de la teledetección, en estas situaciones, se justifica si ofrece menores costes y/o mayor rapidez que los medios ya utilizados (por ejemplo, por tratarse de áreas inaccesibles), manteniendo la precisión requerida.

En otros casos, las aplicaciones que ofrece la teledetección son relativamente originales, pues resultan inasequibles, a un precio razonable, con las técnicas convencionales (cartografía de la clorofila en el agua, detección de vertidos incontrolados de petróleo). Habitualmente se trata de variables que sólo pueden medirse en una red de puntos más o menos dispersa sobre el territorio, lo que supone aplicar técnicas de interpolación/extrapolación para obtener la distribución espacial completa de esa variable. Aunque la gama de estas técnicas es muy variada (Burrough y McDonell, 1998), todas ellas incluyen distintas fuentes de error. Por su parte, las imágenes cubren exhaustivamente el territorio (a la resolución espacial del sensor), por lo que pueden ofrecer una visión espacial mucho más adecuada que las técnicas de interpolación, especialmente si la red de observatorios no cubre algunos sectores críticos del área de estudio (Sánchez y Chuvieco, 2000).

Otro contexto en donde la teledetección resulta la alternativa más razonable afecta a la generación de bases de datos globales, ya que se trata de un medio de observación que todo el planeta, con el mismo o similar sensor, y a intervalos regulares. Esto facilita la generación de algunas variables ambientales para espacios muy heterogéneos y en condiciones de gran consistencia (Chuvieco, 2008*a*).

Además de en estos ámbitos, la teledetección puede ser una alternativa muy conveniente cuando sólo se disponga de información analógica, que sea preciso digitizar, siempre que la escala de trabajo y el nivel de desagregación de la leyenda sean abordables a partir de la imagen de satélite. Al tratarse de información ya digital, las imágenes de satélite pueden integrarse con relativa facilidad, como luego veremos, en un SIG, obviando la labor de digitización, imprescindible a partir de la fotointerpretación o la cartografía temática convencional. No hemos de olvidar que la mayor parte de los países del mundo no cuentan con una cartografía digital suficientemente extendida (Rhind y Clark, 1988): la mayor parte de la información geográfica disponible está constituida por mapas en papel, frecuentemente de distintas escalas y proyecciones. Numerosos autores están de acuerdo en que la digitización de esta cartografía resulta la labor más compleja y costosa en el establecimiento de un SIG (Burrough y McDonell, 1998; Star y Estes, 1990). Además, es la partida más costosa en el desarrollo y mantenimiento de la base de datos; hasta un 70 % en la experiencia del servicio forestal norteamericano: (Lachowski *et al.*, 1992).

Además de la lentitud y elevado coste del proceso de digitización, la entrada de información en un SIG no está exenta de errores. Las causas más importantes de estos defectos son:

— Las inexactitudes en la digitización (polígonos mal etiquetados, desplazamiento de líneas, generalización de elementos).

— La falta de criterios homogéneos entre las personas que compilan la información base.

En consecuencia, no se trata de introducir indiscriminadamente la cartografía disponible, sino de seleccionar la más precisa y duradera, confiando a otros métodos la obtención de nuevas variables o la actualización de las existentes.

5.3. El problema de la actualización

Realizar un inventario cartográfico es sólo una primera parte en la generación de un SIG operativo. El paso siguiente es mantener esa información al día, recogiendo aquellos cambios que se hayan producido entre la fecha de realización del mapa y la actual. En muchas ocasiones, la cartografía que pretende introducirse en un SIG no representa fidedignamente el estado actual del territorio, sino una situación obsoleta, que puede invalidar cualquier análisis posterior de esa información. Datos desactualizados tienen las mismas consecuencias que datos erróneos: llevan a decisiones equivocadas, que pueden tener un efecto social o ambiental de gran trascendencia. Por ello, se reconoce generalmente que la actualización de información, pese al notable esfuerzo que supone, debe incluirse en la gestión permanente de un SIG (Aronoff, 1989; Camarasa *et al.*, 2001).

Como hemos visto a lo largo de esta obra (especialmente en 7.3), las imágenes adquiridas desde el espacio ofrecen magníficas posibilidades para la actualización de datos, al ofrecer adquisiciones sistemáticas y en condiciones similares de observación. Esto permite obtener una visión actualizada de la superficie que se observa, así como seguir la evolución temporal de determinados fenómenos muy dinámicos: crecimiento urbano, estado de los cultivos, inundaciones, erupciones volcánicas, etc. Más aún, la agilidad que proporciona la interpretación digital permite obtener resultados en fecha bastante cercana a la obtención de la imagen, reduciéndose el período entre la realización y la disponibilidad del inventario.

Además de servir para generar nuevas variables, las imágenes espaciales también permiten actualizar la información ya almacenada en el SIG (Smits y Annoni, 1999). Las modalidades de actualización pueden ser diversas. La más sencilla pasa por utilizarlas como «fondo» al que se superponen los límites de las áreas temáticas ya archivadas en el Sistema, una vez que ambos documentos ajusten entre sí con precisión (fig. 9.4). Esa simple superposición visual facilita mucho la actualización de los recintos archivados, incorporando aquellos cambios ocurridos entre la fecha del inventario original y la correspondiente a la nueva imagen. Los ejemplos en el campo de la cartografía urbana son muy numerosos: nuevas construcciones, infraestructuras, ejes viarios, etc. De hecho algunas ciudades ya utilizan las imágenes de alta resolución espacial para actualizar su información urbana y mejorar la gestión de las nuevas construcciones. También pueden ponerse otros ejemplos en la actualización de espacios forestales tras quemas o talas, los cambios de cultivo, o la incorporación de nuevos caminos, carreteras y embalses. En esta línea se situaría la conexión entre información cartográfica de base e imágenes de satélite que realizan los servidores de imágenes, principalmente *Google Earth* y *Worldwind,* que sirven de base para situar información espacial muy variada (Butler, 2006; Beck, 2006).

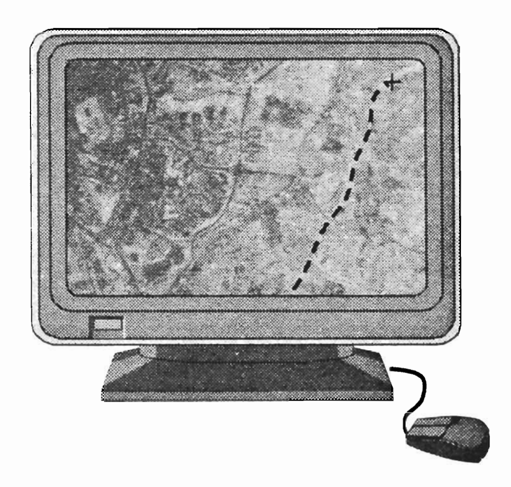


FIG. 9.4. *Una imagen de satélite puede usarse como soporte gráfico para actualizar información geográfica.*

6. Integración de imágenes en un SIG

Si bien las imágenes espaciales se adquieren en formato digital, también es posible abordar una interpretación visual de las mismas, por lo que la integración de imágenes espaciales en un SIG puede realizarse de distintas formas (fig. 9.5):

1. Digitizando un mapa temático obtenido a partir de la interpretación visual de la imagen.
2. Digitizando un mapa temático en papel obtenido a partir de la clasificación digital de la imagen.
3. Superponiendo visualmente la información de un SIG vectorial sobre una imagen de satélite, digitizando sobre la imagen los sectores que hayan cambiado.
4. Incorporando directamente el fichero generado por la clasificación digital de la imagen.
5. Integrando en el SIG los valores digitales originales o los obtenidos a partir de una transformación de la imagen (índices de verdor, estimación de la temperatura del agua, albedo, etc.).

Resulta obvio que estas dos últimas son las opciones más convenientes, puesto que proporcionan información al SIG obviando la tarea de digitización. Como ya hemos visto, la clasificación digital de imágenes en teledetección proporciona un fichero numérico, en donde cada píxel cuenta con un valor entero que indica la categoría en la cual se incluyó. Por tratarse de una información digital, la integración en un SIG no resulta muy problemática.

La forma concreta de llevar a cabo esta integración depende, primordialmente, de la estructura de almacenamiento del SIG y del tipo de interpretación de la imagen que se haya efectuado. Si se optó por una interpretación visual y posterior digitización, la conexión con un SIG de tipo vectorial es bastante directa, mientras re-

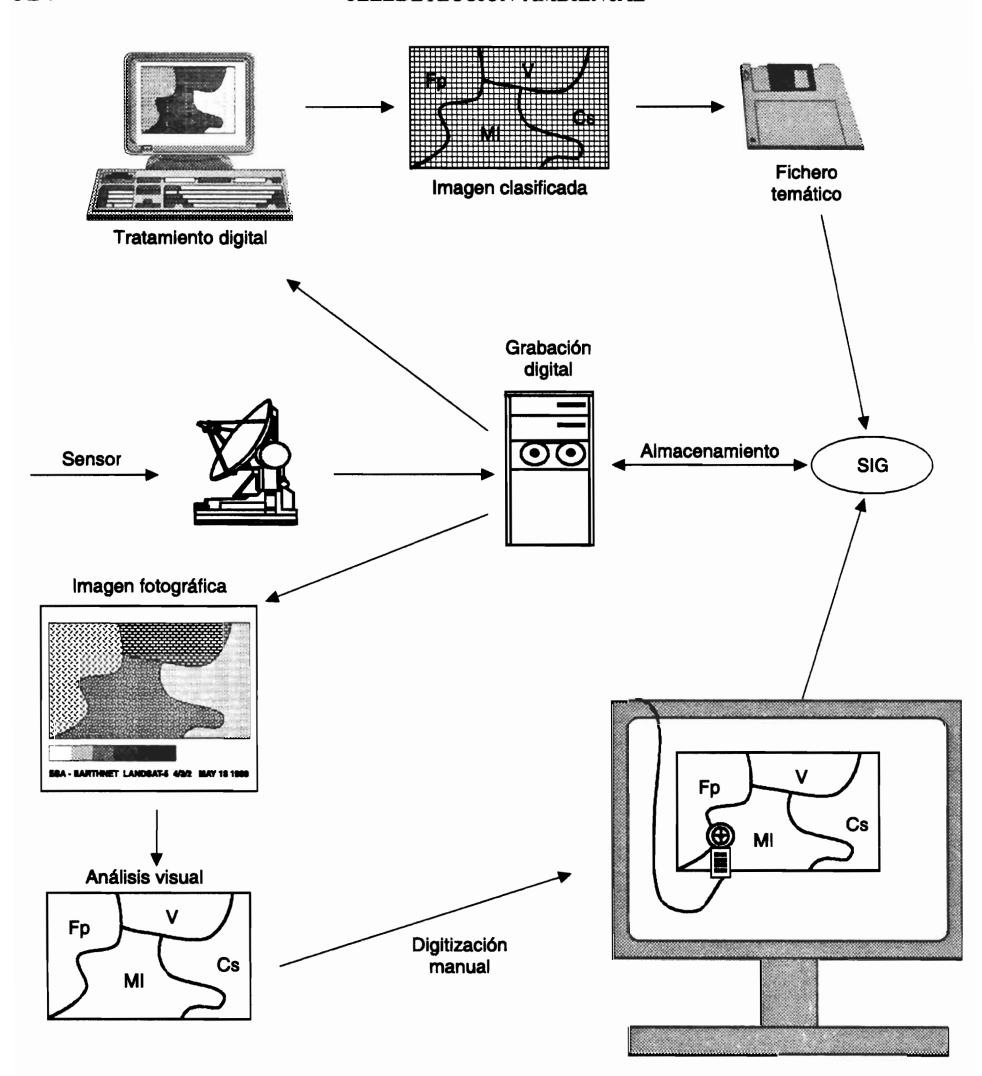


FIG. 9.5. *Modalidades de conexión entre la teledetección y los SIG.*

querría una conversión vectorial a ráster para integrarse en un SIG con este formato. En ambos casos, la entrada de información es similar a la aplicable en el caso de cartografía convencional, siendo las ventajas de la teledetección su mayor accesibilidad temporal y menores errores geométricos.

Como hemos indicado, resulta mucho más conveniente la conexión entre las imágenes y el SIG cuando la interpretación se realizó digitalmente, ya que podemos obviar la digitización de los resultados. Ahí se presentan dos alternativas, según se trate de SIG ráster o vectoriales (fig. 9.6). En el primer caso, podemos considerar al píxel como la unidad teselar de un SIG ráster, por lo que la conexión resulta mucho más directa. Si se trata de un SIG vectorial, resultará preciso transformar el resultado a una lista de coordenadas, utilizando técnicas de vectorización, como luego comentaremos.

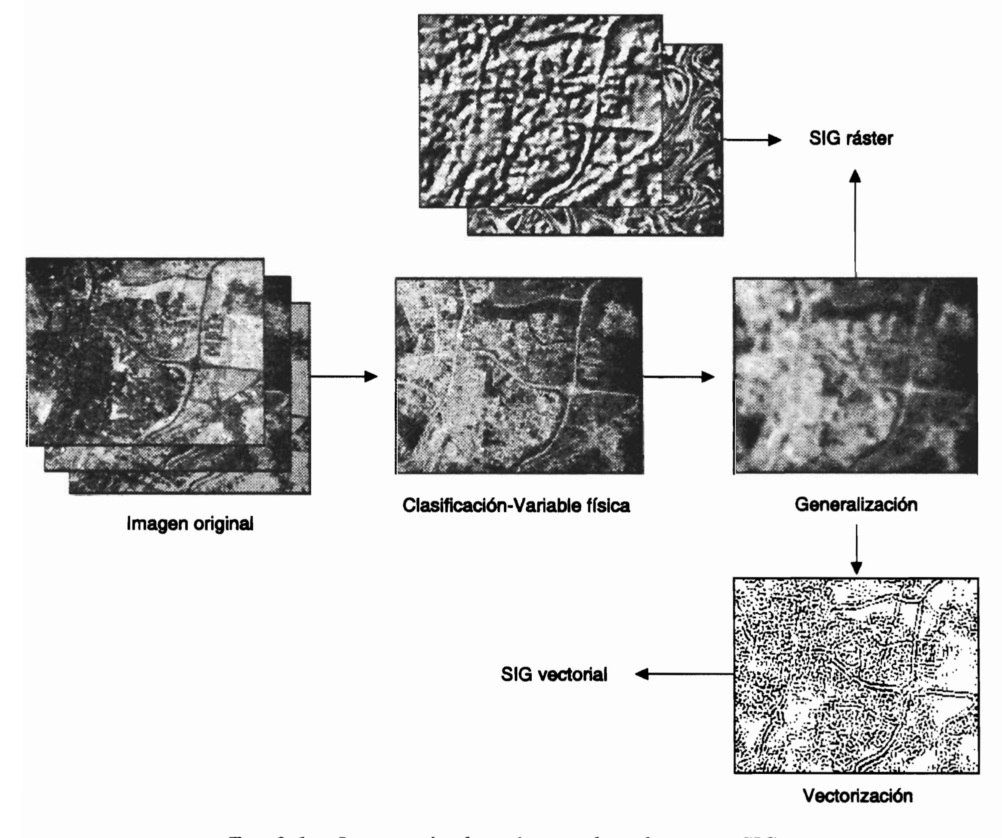


FIG. 9.6. *Integración de imágenes digitales en un SIG.*

En cualquier caso, para integrar una imagen clasificada o una variable biofísica generada a partir de la interpretación de imágenes, es preciso resolver dos problemas geométricos. Por un lado, que las características cartográficas de la imagen coincidan con las del SIG. Por otro, para el caso de los SIG ráster que el tamaño del píxel y el origen de coordenadas sean el mismo. Para resolver ambos aspectos, tendremos que aplicar distintas operaciones según las características cartográficas de la imagen a introducir al SIG. En este sentido, puede ocurrir alguna de las siguientes situaciones (fig. 9.7): 1) que la imagen no esté georreferenciada, 2) que ya lo esté, pero tenga una proyección y/o tamaño del píxel distintos a las del SIG, y 3) que tenga la misma proyección y tamaño del píxel, pero no el mismo origen de coordenadas.

En caso de que la imagen no esté georreferenciada, se utilizarán los procedimientos de corrección geométrica antes comentados (6.6.3), utilizando como referencia la proyección cartográfica del SIG, lo que garantizará que la imagen de salida tenga sus mismas propiedades geométricas. En ese caso, sólo será necesario asegurar en la interpolación final que la ventana a corregir (coordenadas de las esquinas), así como el tamaño del píxel de salida, coinciden con las demás variables cartográficas almacenadas en el SIG. De otro modo, no podrán integrarse los resultados al SIG,

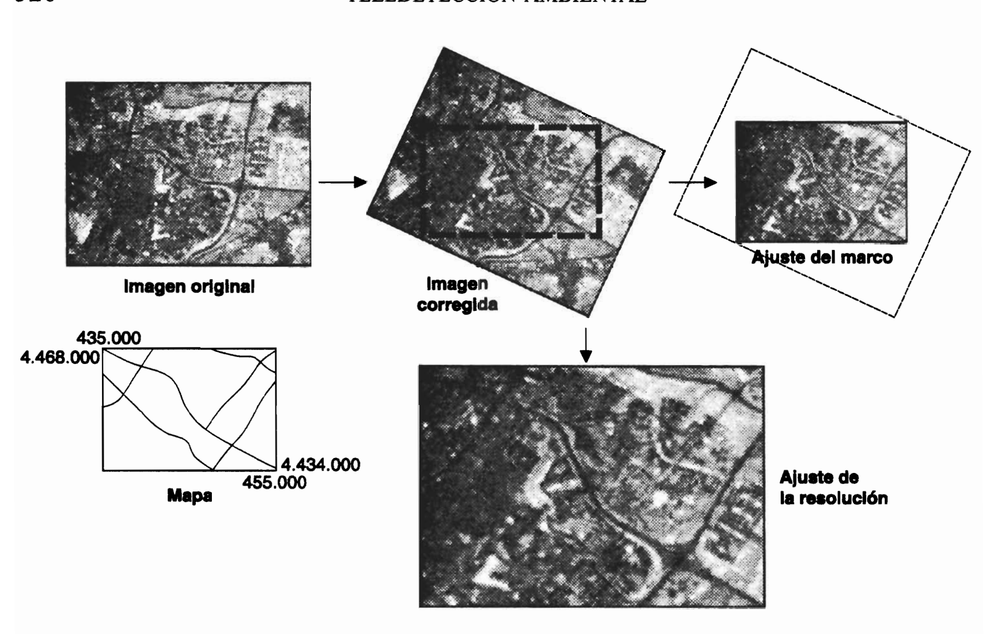


FIG. 9.7. *Aspectos geométricos en la integración de imágenes a un SIG.*

puesto que la mayor parte de estos programas sólo pueden poner en relación ficheros que tengan el mismo número de filas y columnas.

En caso de que la imagen ya esté georreferenciada, pero no a la base cartográfica del SIG (no coinciden proyección y/o elipsoide de referencia y/o datum), deberá realizarse una nueva corrección geométrica de la imagen, aunque en este caso sólo en su tercera fase (interpolación), ya que la transformación de un sistema de coordenadas a otro puede modelarse a priori (no necesitamos puntos de control para estimar la transformación, por tanto). La mayor parte de los programas de ADI cuentan con una amplia lista de proyecciones cartográficas definidas, por lo que pasar de una a otra, resultará un proceso bastante automático, consistente en un remuestreo (por cualquiera de los procesos de trasvase de ND comentados en 6.6.3), de la proyección inicial a la deseada. El mismo hecho se daría cuando la imagen coincidiera cartográficamente con el SIG, pero el tamaño del píxel fuera distinto. También sería preciso, entonces, remuestrear la imagen, aunque lógicamente en ese caso no se modificaría la geometría de partida.

Finalmente, puede ocurrir que coincidan la proyección, elipsoide y tamaño de píxel entre la imagen y el SIG, pero no las coordenadas límite del marco geográfico que abarcan (esto es, las coordenadas de las esquinas). En ese caso, también es preciso realizar una transformación, aunque se limite a recortar o ampliar el marco de la imagen, para que el archivo de salida tenga el mismo número de filas y de columnas que el resto de las variables almacenadas en el SIG.[1]

1. Para que esto sea posible, es necesario que las coordenadas del área de referencia del SIG coincidan, en algún lugar de la malla, con las de la imagen. De lo contrario, será necesario optar por la opción anterior (remuestrear la imagen), ya que sólo pueden recortarse en la imagen píxeles enteros. Este sería el caso si el origen del SIG fuera, por ejemplo, de 435000 y 4467000, mientras la imagen contara

En caso de trabajar con un SIG de tipo vectorial, los matices del ajuste geométrico son menos delicados, ya que no necesitamos considerar el tamaño del píxel, ni frecuentemente tampoco la ventana de coordenadas (la imagen puede abarcar una zona más grande o más pequeña que la incluida en el SIG). No obstante, sí es necesario que la proyección, elipsoide y datum coincidan. Posteriormente, es preciso abordar una conversión de estructura ráster a vectorial (vectorización), utilizando algoritmos de «adelgazamiento» de píxeles y reconstrucción automática de líneas. Estos programas suelen ser bastante automáticos, pero también pueden cometer notables errores, por lo que se recomienda una cierta supervisión por parte del intérprete, especialmente en los sectores de la imagen de mayor complejidad espacial (múltiples cruces). Para realizar eficazmente esa tarea, resulta casi imprescindible suavizar previamente la imagen, eliminando píxeles con asignaciones aisladas del contexto. Lo habitual, con este propósito, es utilizar filtros modales (7.2.3.5), que resultan muy apropiados para imágenes clasificadas. En caso de que intentemos incorporar a un SIG una imagen correspondiente a una variable de intervalo (p. ej., temperatura), será más conveniente utilizar algoritmos de interpolación de líneas, frecuentemente utilizados para generar curvas de nivel en un MDE.

Un último aspecto que hace referencia a la integración entre la teledetección y los SIG lleva a considerar los mecanismos para combinar variables generadas en uno u otro contexto. Como ya comentamos más arriba, esta mezcla de fuentes puede considerarse una modalidad específica de las técnicas de fusión de datos (Gong, 1994). En este sentido, se han propuesto diversas técnicas para integrar variables de distintas procedencia, como puede ser la Teoría de la Decisión (Gong, 1996), la Evaluación Multicriterio, y las redes neuronales (Hewitson y Crane, 1994).

Independientemente de los problemas que pueda traer consigo, la conexión de la teledetección espacial con un SIG es, a nuestro juicio, la conclusión más lógica del empleo de esta técnica. Brinda enormes posibilidades para la realización de estudios ambientales, evaluación de recursos, análisis de impactos, modelos de localización, etc. Con el apoyo de estos sistemas informáticos, el estudioso del medio ambiente podrá preocuparse más del análisis que de la obtención de la información. Será posible diseñar alternativas para un proyecto, estimar comportamientos futuros, y simular efectos antes de que éstos sean irreparables.

---

con un origen en 434925 y 4467025, con un tamaño de píxel de 50 m. Habría medio píxel de la imagen original en la nueva, lo que no es posible. Sí se podría recortar, en cambio, esa imagen si el píxel de salida tuviera un tamaño de 25 m.

REFERENCIAS BIBLIOGRÁFICAS

Ackerman, S.; Strabala, K.; Menzel, P.; Frey, R.; Moeller, C. y Gumley, L. (1998): «Discriminating clear sky from clouds with MODIS», *Journal of Geophysical Research*, 103: 141-157.

Adams, J. B.; Smith, M. O. y Johnson, P. E. (1986): «Spectral mixture modelling: a new analysis of rock and soil types at the Viking Lander I site», *Journal of Geophysical Research*, 91: 8098-8112.

Adams, J. B.; Sabol, D. E.; Kapos, V.; Almeida, R.; Roberts, D. A.; Smith, M. O. y Gillespie, A. R. (1995): «Classification of Multispectral Images Based on Fractions of Endmembers: Application to Land-Cover Change in the Brazilian Amazon», *Remote Sensing of Environment*, 52: 137-154.

Adeniyi, P. O. (1985): «Digital analysis of multitemporal Landsat data for land use/land cover classification in a semi-arid area of Nigeria», *Photogrammetric Engineering and Remote Sensing*, 51: 1761-1774.

— (1987): «Using remotely sensed data for census surveys and population estimation in developing countries: examples from Nigeria», *Geocarto International*, 2: 11-32.

Ahern, F. J.; Goldammer, J. G. y Justice, C. O. (eds.) (2001): *Global and Regional Vegetation Fire Monitoring from Space: Planning a coordinated international effort*, The Haghe, The Netherlands, SPB Academic Publishing.

Alía, M.; Martín, C.; Ubanell, A. G. y Muñoz, L. (1976): «Determination by means of Landsat images of different geological structures in the central areas of the Iberian Plateau», en *Thematic Mapping, Land Use, Geological Structure and Water Resources in Central Spain* (editado por R. Nuñez de las Cuevas). Madrid, NASA Project 28760: 172-208.

Allan, T. D. (ed.) (1983): *Satellite Microwave Remote Sensing*, Nueva York, Ellis Howard Ltd.

Anderson, J. R.; Hardy, E. E.; Roach, J. T. y Witmer, R. E. (1976): *A Land Use and Land Cover Classification System for Use with Remote Sensor Data*, Washington, D.C., U.S. Geological Survey, Prof. Paper 964.

Aplin, P.; Atkinson, P. y Curran, P. J. (1999): «Per-field classification of land use using the forthcoming very fine spatial resolution satellite sensors: problems and potential solutions», en *Advances in Remote Sensing and GIS analysis* (editado por P. M. Atkinson y N. J. Tate). Chichester, John Wiley & Sons: 219–239.

Arbiol, R.; Arozarena, A. y Villa, G. (1994): «Cartografía digital en áreas sin cobertura de mapas en la cuenca del Orinoco en Venezuela, mediante imágenes de satélite, fotos aéreas infrarrojo y GPS», *Revista Española de Teledetección*, 3: 58-59.

Aronoff, S. (1982): «The map accuracy report: A user's view», *Photogrammetric Engineering and Remote Sensing*, 48: 1309-1312.

Aronoff, S. (1989): *Geographic Information Systems: a management perspective*, Ottawa, WDL Publications.

Arozarena, A.; Calero, E.; Delgado, J. y Vivas, P. (1989): «Aplicaciones de las imágenes es-

paciales a la cartografía de base», en *Coloquio Hispano-Francés sobre Teledetección y Planificación Integrada del Territorio* (editado por R. Núñez de las Cuevas y F. Fourneau). Madrid, I.G.N.: 215-223.

Arozarena, A.; Villa, G.; Hermosilla, J.; Papí, F.; Valcárcel, N.; Peces, J. J.; Doménech, E. y Tejeiro, J. A. (2006): «El plan nacional de observación del territorio en España: situación actual y próximos pasos», *Mapping Interactivo*, 111: http://www.mappinginteractivo.com

Arroyo, L. A.; Healey, S. P.; Cohen, W. B.; Cocero, D. y Manzanera, J. A. (2006): «Using object-oriented classification and high-resolution imagery to map fuel types in a Mediterranean region», *Journal of Geophysical Research-Biogeosciences*, 111: doi:10.1029/2005JG000120.

Asrar, G. (Ed.) (1989): *Theory and Applications of Optical Remote Sensing*, Nueva York, Wiley.

Asrar, G.; Myneni, R. M. y Kanemasu, E. T. (1989): «Estimation of plant canopy attributes from spectral reflectance measurements», en *Theory and Applications of Optical Remote Sensing* (editado por G. Asrar). Nueva York, Wiley: 252-296.

Astaras, T. (1984): «Land complex classification of the Mula area, Murcia Province, Southeast Spain», *Geografiska annaler*, 66A: 307-325.

Atkinson, P.; Cushnie, J. L.; Townshend, J. R. G. y Wilson, A. (1985): «Improving Thematic Mapper land cover classification using filtered data», *International Journal of Remote Sensing*, 6: 955-961.

Au, K. N. (Ed.) (1993): *Cities of the world as seen from space*, Hong-Kong, Geocarto International Centre.

Bachmann, M. y Bendix, J. (1992): «An improved algorithm for NOAA-AVHRR image referencing», *International Journal of Remote Sensing*, 13: 3205-3215.

Baker, J. C. (2001): «New users and established experts: bridging the knowledge gap in interpreting commercial satellite imagery», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 533-557.

Baker, J. C.; Williamson, R. A. y O'Connell, K. M. (2001): «Introduction», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 1-16.

Baltsavias, E. P. (1999): «Airborne laser scanning: existing systems and firms and other sources», *ISPRS Journal of Photogrammetry and Remote Sensing*, 54: 164-198.

Bannari, A.; Morin, D.; Bonn, F. y Huete, A. R. (1995): «A review of vegetation indices», *Remote Sensing Reviews*, 13: 95-120.

Barbosa, P. M.; Grégoire, J. M. y Pereira, J. M. C. (1999): «An algorithm for extracting burned areas from time series of AVHRR GAC data applied at a continental scale», *Remote Sensing of Environment*, 69: 253-263.

Baret, F. (1995): «Use of spectral reflectance variation to retrieve canopy biophysical characteristics», en *Advances in Environmental Remote Sensing* (editado por F. M. Danson y S. E. Plummer). Chichester, John Wiley & Sons: 33-51.

Baret, F. y Fourty, T. (1997): «Estimation of leaf water content and specific leaf wight from reflectance and transmitance measurements», *Agronomie*, 17: 455-44.

Barnsley, M. J. y Hobson, P. (1997): «Teaching the principles of optical remote sensing using graphical tools developed in TCL/TK», *Remote Sensing Society Annual Conference*.

Barr, S. y Barnsley, M. J. (2000): «Reducing structural clutter in land cover classifications of high spatial resolution remotely-sensed images for urban land use mapping», *Computers and Geosciences*, 26: 433-449.

Barret, E. C. (1974): *Climatology from Satellites*, Londres, Methuen.

Barret, E. C. y Curtis, L. F. (1999*a*): «Calibration, evaluation and validation in remote sen-

sing», en *Introduction to Environmental Remote Sensing* (editado por Cheltenham, Stanley Thornes Publishers Ltd: 117-134).

— (1999*b*): *Introduction to Environmental Remote Sensing*, Cheltenham, Stanley Thornes Publishers Ltd.

Barreto, M. M. (2000): «Las imágenes NOAA y los recursos pesqueros en el litoral peruano», *IX Simposio Latinoamericano de Percepción Remota*, Iguazú.

Bartholome, J. E. y Belward, A. S. (2005): «GLC2000: a new approach to global land cover mapping from Earth observation data», *International Journal of Remote Sensing*, 26: 1959-1977.

Bastarrika, A. (2000): *Desarrollo de rutinas de pre-procesamiento de imágenes AVHRR*, Departamento de Geografía, Alcalá de Henares, Universidad de Alcalá: 106.

Baudot, Y. (1990): «Integration of high-quality remote sensing images with low cost geographical information systems», *EGIS'90*, Utrecht: 40-46.

Bauer, T. y Steinnocher, K. (2001): «Per-parcel land use classification in urban areas applying a rule-based technique», *GIS*, 6: 24-27.

Beaven, P. J. (1988): «A very low-cost microcomputer-based image processor», en *Digital Image Processing in Remote Sensing* (editado por J. P. Muller). Londres, Taylor & Francis: 123-133.

Beck, A. (2006): «Google Earth and World Wind: remote sensing for the masses?», *Antiquity 80,* No 308. (http://antiquity.ac.uk/projgall/beck/)

Becker, F. y Choudhury, B. J. (1988): «Relative Sensitivity of Normalized Difference Vegetation Index (NDVI) and Microwave Polarization Difference Index (MPDI) for Vegetation and Desertification Monitoring», *Remote Sensing of Environment*, 24: 297-311.

Belward, A. S. (1991): «Spectral Characteristics of vegetation, Soil and Water in the Visible, Near-Infrared and Middle-Infrared Wavelengths», en *Remote Sensing and GIS for Resource Management in Developing Countries* (editado por A. S. Belward y C. R. Valenzuela), Dordrecht, Kluwer Academic Publishers: 31-53.

Benediktsson, J. A.; Swain, P. H. y Ersoy, O. K. (1990): «Neural network approaches versus statistical methods in classification of multisource remote sensing data», *IEEE Transactions on Geoscience and Remote Sensing*, 28: 540-552.

Benson, A. S. y Degloria, S. (1984): «Interpretation of Landsat-4 Thematic Mapper and Multispectral Scanner data for forest surveys», *Photogrammetric Engineering and Remote Sensing*, 51: 1281-1289.

Benson, B. J. y Mackenzie, M. D. (1995): «Effects of sensor spatial resolution on landscape structure parameters», *Landscape Ecology*, 10: 113-120.

Berk, A.; Anderson, G. P.; Bernstein, L. S.; Acharya, P. K.; Dothe, H.; Matthew, M. W.; Adler-Golden, S. M.; Chetwynd, J. H.; Richtsmeier, S. C.; Pukall, B.; Allred, C. L.; Jeong, L. S. y Hoke, M. L. (1999): «MODTRAN4 Radiative Transfer Modeling for Atmospheric Correction», *SPIE Proceeding, Optical Spectroscopic Techniques and Instrumentation for Atmospheric and Space Research III.*

Bernstein, R. (1978): «Digital image processing of Earth observation sensor data», en *Digital Image Processing for Remote Sensing* (editado por R. Bernstein). Nueva York, IEEE Press: 55-72.

Bernstein, R.; Lotspiech, J. B.; Myers, J.; Kolskoy, H. G. y Lees, R. D. (1984): «Analysis and processing of Landsat-4 sensor data using advanced image processing techniques and technologies», *IEEE Transaction on Geoscience and Remote Sensing*, GE-22: 192-221.

Berry, B. J. y Baker, A. M. (1968): «Geographic Sampling», en *Spatial Analysis* (editado por B. J. Berry y D. F. Marble). Nueva Jersey, Englewood Cliffs: 91-100.

Bhargava, D. S. y Mariam, D. W. (1990): «Spectral reflectance relationships to turbidity ge-

nerated by different clay materials», *Photogrammetric Engineering and Remote Sensing*, 56: 225-229.

Biging, G.; Colby, D. R. y Congalton, R. G. (1998): «Sampling Systems for Change Detection Accuracy Assessment», en *Remote Sensing Change Detection. Environmental Monitoring Methods and Applications* (editado por R. S. Luneta y C. D. Elvidge). Chelsea, MI, Ann Arbor Press: 281-308.

Bischof, H.; Schneider, W. y Pinz, A. J. (1992): «Multispectral classification of Landsat images using neural networks», *IEEE Transactions on Geoscience and Remote Sensing*, 30: 482-489.

Bishop, Y.; Fienberg, S. y Holland, P. (1975): *Discrete Multivariate Analysis: Theory and Practice*, Cambridge, MIT Press.

Blom, R. G. y Daily, M. (1982): «Radar image processing for rock-type discrimination», *IEEE Transactions on Geoscience Electronics*, GE20: 343-351.

Boardman, J. B.; Kruse, F. A. y Green, R. O. (1995): «Mapping target signatures via partial unmixing of AVIRIS data», *Fifth Annual JPL Airborne Earth Science Workshop*, Pasadena, CA, NASA, Jet Propulsion Laboratory: 23-26.

Booth, D. J. y Oldfield, R. B. (1989): «A comparison of classification algorithms in terms of speed and accuracy after the applications of a post-classification modal filter», *International Journal of Remote Sensing*, 10: 1271-1276.

Bordes, P.; Brunel, P. y A.; M. (1992): «Automatic adjustment of AVHRR navigation», *Journal of Atmospheric and Oceanic Technology*, 9: 15-27.

Boschetti, L.; Brivio, P. A.; Eva, H. D.; Gallego, J.; Baraldi, A. y Gregoire, J. M. (2006): «A sampling method for the retrospective validation of Global Burned Area products», *IEEE Transactions on Geoscience and Remote Sensing*, 44: 1765-1773.

Bosque, J. (1997): *Sistemas de Información Geográfica*, Madrid, Rialp.

Bossard, M.; Feranec, J. y Otahel, J. (2000): *CORINE land cover technical guide–Addendum 2000*, Copenhague, European Environmental Agency.

Bowman, W. D. (1989): «The relationship between leaf water status, gas exchange, and spectral reflectance in cotton leaves», *Remote Sensing of Environment*, 30: 249-255.

Bowyer, P. y Danson, F. M. (2004): «Sensitivity of spectral reflectance to variation in live fuel moisture content at leaf and canopy level», *Remote Sensing of Environment*, 92: 297-308.

Briggs, J. y Nellis, D. (1991): «Seasonal variation of heterogeneity in the tallgrass prairie: a quantitative measure using remote sensing», *Photogrammetric Engineering and Remote Sensing*, 57: 407-411.

Bronsveid, M. C. y Luderus, F. J. D. (1982): *Analysis of Multi-temporal Data for the Identification of Land Use and crops (Case Study on the Mérida Region in the Province of the Badajoz, SW Spain)*, Madrid, ITC-IBM Scientific Center.

Brookes, A. J. (1975): *Photo Reconnaissance: The Operational History*, Londres, Ian Allan.

Brown, J. F.; Loveland, T. R.; Merchant, J.; Reed, B. C. y Ohlen, D. O. (1993): «Using multisource data in global land-cover characterization: concepts, requirements, and methods», *Photogrammetric Engineering and Remote Sensing*, 59: 977-987.

Brown, J. K.; Booth, G. D. y Simmerman, D. G. (1989): «Seasonal Change in Live Fuel Moisture of Understory Plants in Western U.S. Aspen», *10th Conference on Fire and Forest Meteorology*, Ottawa, Canada: 406-412.

Bruce, B. y Hormsby, J. K. (1987): «A Canadian perspective on the application of satellite remote sensing to regional geobotany», *Geocarto International*, 1: 53-59.

Bruneau, M. y Gautier, B. (1981): «Cartographie diachronique de l'occupation du sol en milieu tropical densement peuple (Thailande)», *4eme Coll. Inter. du GDTA*, Toulousse: 230-240.

Bruzzone, L. y Fernández-Prieto, D. (2000): «An adaptive parcel-based technique for unsupervised change detection», *International Journal of Remote Sensing*, 21: 817-822.

Bullard, R. K. y Dixon-Gough, R. W. (1985): *Britain from Space. An Atlas of Landsat Images*, Londres, Taylor & Francis Ltd.

Burgan, R. E.; Klaver, R. W. y Klaver, J. M. (1998): «Fuel models and fire potential from satellite and surface observations», *International Journal of Wildland Fire*, 8: 159-170.

Burrough, P. A. y Mcdonell, R. A. (1998): *Principles of Geographical Information Systems*, Oxford, Oxford University Press.

Butler, D. (2006): «The web-wide world», *Nature*, 439: 776-778.

Byrne, G. F.; Crapper, P. F. y Mayo, K. K. (1980): «Monitoring land-cover change by Principal Component analysis of multitemporal Landsat Data», *Remote Sensing of Environment*, 10: 175-184.

Cabral, A.; Vasconcelos, M. J. P. D.; Pereira, J. M. C.; Bartholome, J. E. y Mayaux, P. (2003): «Multi-temporal compositing approaches for SPOT-4 VEGETATION», *International Journal of Remote Sensing*, 24: 3343-3350.

Cachorro, V. E.; Durán, P.; Vergaz, R. y Frutos, A. M. (2000): «Estudio de la influencia de los aerosoles sobre la reflectancia de los canales 1 y 2 del sensor AVHRR-NOAA y el NDVI», *Revista de Teledetección*, 13: 13-26.

Caetano, M. y Oliveira, T. (1998): *The CNIG Digital Spectral Library*, Lisboa, CNIG,

Caetano, M. S.; Mertes, L. A. K. y Pereira, J. M. C. (1994): «Using Spectral Mixture Analysis for Fire Severity Mapping», en *Proceedigns of 2nd International Conference on Forest Fire Research* (editado por Coimbra: 667-677).

Caetano, M. S.; Mertes, L.; Cadete, L. y Pereira, J. M. C. (1996): «Assessment of AVHRR data for characterising burned areas and post-fire vegetation recovery», *EARSeL Advances in Remote Sensing*, 4: 124-134.

Calvet, J. y Pascual, R. (1987): «Estudio de alineaciones obtenidas a partir de imágenes radar del Seasat-SAR en el macizo del Montseny-Guilleries», *II Reunión Científica del Grupo de Trabajo en Teledetección*: 41-47.

Calle, A.; Casanova, J. L. y Romo, A. (2006): «Fire detection and monitoring using MSG Spinning Enhanced Visible and Infrared Imager (SEVIRI) data», *Journal of Geophysical Research - Biosciences*, 111: doi:10.1029/2005JG000116.

Camarasa, A. M.; Salas, J. y Chuvieco, E. (2001): «Información geográfica y riesgos naturales», *El Campo de las Ciencias y las Artes (Servicio de Estudios del BBVA)*, 138: 103-136.

Campbell, J. B. (1981): «Spatial correlation effects upon accuracy of supervised classification of land cover», *Photogrammetric Engineering and Remote Sensing*, 47: 355-363.

— (1996): *Introduction to Remote Sensing*, Nueva York, The Guilford Press.

Cañón, M. L. (2000): «Aplicación de la teledetección para la determinación de indicadores de áreas con mayor probabilidad de pesca en el sector noreste del Caribe Colombiano», *IX Simposio Latinoamericano de Percepción Remota*, Iguazú.

Carleton, A. M. (1991): *Satellite Remote Sensing in Climatology*, Londres, Belhaven Press.

Carper, W. J.; Lillesand, T. M. y Kiefer, R. W. (1990): «The use of Intensity-Hue-Saturation transformation for merging SPOT pancromatic and multispectral image data», *Photogrammetric Engineering and Remote Sensing*, 56: 459-467.

Carter, D. J. (1986): *The Remote Sensing Sourcebook*, Londres, McCarta Ltd.

Carter, G. A. (1991): «Primary and secondary effects of water content on the spectral reflectance of leaves», *American Journal of Botany*, 78: 916-924.

Carter, P. y Stow, B. (1979): «Clean-up of digital thematic maps of urban growth extracted from Landsat imagery», en *Remote Sensing and National Mapping* (editado por J. A. Allan y R. Harris). Reading, Remote Sensing Society: 27-40.

Carvacho, L. (1998): «Evaluación de la estimación de grandes incendios forestales en la cuenca mediterránea europea por redes neuronales y regresión logística», *Serie Geográfica*, 7: 73-85.

Casas, J. M. y Chuvieco, E. (1987): «Análisis visual de imágenes "Thematic Mapper" para el estudio urbano. El caso de la ciudad de Madrid», *Anales de Geografía de la Universidad Complutense*, 7: 401-415.

Caselles, V. (1987): «La utilidad del semivariograma en estudios de teledetección», *II Reunión Nacional del Grupo de Trabajo en Teledetección*, Valencia: 121-129.

Caselles, V. y Sobrino, J. A. (1989): «Determination of frosts in orange groves from NOAA-9 AVHRR Data», *Remote Sensing of Environment*, 29: 135-146.

Caselles, V.; Sobrino, J. A. y Becker, F. (1988): «Determination of the effective emissivity and temperature under vertical observation of a citrus orchard. Application to frost nowcasting», *International Journal of Remote Sensing*, 9: 715-727.

Caselles, V. y López, M. J. (1989): «An alternative simple approach to estimate atmospheric correction in multitemporal studies», *International Journal of Remote Sensing*, 10: 1127-1134.

Caselles, V.; Coll, C.; Rubio, E.; Sospedra, F. y Valor, E. (1995): «La medida de la temperatura y de la emisividad desde satélites: estado actual y perspectivas futuras», *VI Reunión Científica de la Asociación Española de Teledetección*, Valladolid: 487-492.

Castleman, K. E. (1978): «The Gray Level Histogram», en *Digital Image Processing* (editado por Englewood Cliffs, Prentice Hall: 68-84).

Castro, R. y Chuvieco, E. (1998): «Modeling Forest Fire Danger From Geographic Information Systems», *Geocarto International*, 13: 15-23.

Cebrián, J. A. (1988): «Sistemas de Información Geográfica», en *Aplicaciones de la Informática a la Geografía y Ciencias Sociales* (editado por J. Bosque). Madrid, Síntesis: 125-140.

Ceccato, P.; Flasse, S.; Tarantola, S.; Jacquemoud, S. y Grégoire, J. M. (2001): «Detecting vegetation leaf water content using reflectance in the optical domain», *Remote Sensing of Environment*, 77: 22-33.

Ceccato, P.; Flasse, S. y Gregoire, J. M. (2002): «Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications», *Remote Sensing of Environment*, 82: 198–207.

Ceccato, P.; Leblon, B.; Chuvieco, E.; Flasse, S. y Carlson, J. D. (2003): «Estimation of Live Fuel Moisture Content», en *Wildland Fire Danger Estimation and Mapping. The Role of Remote Sensing Data* (editado por E. Chuvieco). Singapur, World Scientific Publishing: 63-90.

Cibula, W. G.; Zetka, E. F. y Rickman, D. L. (1992): «Response of Thematic Mapper bands to plant water stress», *International Journal Remote Sensing*, 13: 1869-80.

Cicone, R. y Metzler, M. D. (1984): «Comparison of Landsat MSS, Nimbus-7 CZCS, and NOAA-7 AVHRR features for land use analysis», *Remote Sensing of Environment*, 14: 257-265.

Cihlar, J.; St.-Laurent, L. y Dyer, J. A. (1991): «Relation between the Normalized Difference Vegetation Index and ecological variables», *Remote Sensing of Environment*, 35: 279-298.

Cihlar, J.; Manak, D. y Voisin, N. (1994): «AVHRR bidirectional reflectance effects and compositing», *Remote Sensing of Environment*, 48: 77-88.

Cihlar, J.; Xiao, Q.; Chen, J.; Peaubien, J.; Fung, K. y Latifovic, R. (1998): «Classification by progressive generalization: a new automated methodology for remote sensing multichanel data», *International Journal of Remote Sensing*, 19: 2685-2704.

Civco, D. L. (1989): «Topographic Normalization of Landsat Thematic Mapper Digital Imagery», *Photogrammetric Engineering and Remote Sensing*, 55: 1303-1309.

— (1993): «Artificial neural networks for land-cover classification and mapping», *International Journal of Geographical Information Systems*, 7: 173-186.
Clark, C. y Cañas, A. (1995): «Spectral identification by artificial neural network and genetic algorithm», *International Journal of Remote Sensing*, 16: 2256-2272.
Clark, R. N.; Swayze, G. A.; Gallagher, A. J.; King, T. V. V. y Calvin, W. M. (1993): *The U.S. Geological Survey, Digital Spectral Library: Version 1: 0.2 to 3.0 microns*, U.S. Geological Survey Open File Report, 93-592.
Cliff, A. D. y Ord, J. K. (1973): *Spatial Autocorrelation*, Londres, Pion.
Cohen, W. B. (1991): «Response of vegetation indices to changes in three measures of leaf water stress», *Photogrammetric Engineering and Remote Sensing*, 57: 195-202.
Cohen, W. B. y Spies, T. A. (1992): «Estimating structural attributes of Douglas-fir / Western Hemlock forest stands from Landsat and SPOT imagery», *Remote Sensing of Environment*, 41: 1-17.
Cohen, W. B.; Spies, T. A. y Fiorella, M. (1995): «Estimating the Age and Structure of Forests in a Multi-Ownership Landscape of Western Oregon, Usa», *International Journal of Remote Sensing*, 16: 721-746.
Cohen, W. P.; Spies, T. A. y Bradshaw, G. A. (1990): «Semivariograms of digital imagery for analysis of conifer canopy structure», *Remote Sensing of Environment*, 34: 167-178.
Colby, J. D. (1991): «Topographic normalization in rugged terrain», *Photogrammetric Engineering and Remote Sensing*, 57: 531-537.
Coleman, A. (1968): *Land Use Survey Handbook*, Isla de Thamet, Geographical Association.
Colwell, J. E. (1974): «Vegetation canopy reflectance», *Remote Sensing of Environment*, 3: 175-183.
Coll, C.; Caselles, V.; Sobrino, J. A. y Valor, E. (1994): «On the atmospheric dependence of the split winclow equation for land surface temperature», *International Journal of Remote Sensing*, 15: 105-122.
Collado, A. D.; Chuvieco, E. y Camarasa, A. (2002): «Satellite remote sensing analysis to monitor desertification processes in the crop-rangeland boundary of Argentina», *Journal of Arid Environments*, 52: 121–133.
Comas, D. y Ruiz, E. (1993): *Fundamentos de los Sistemas de Información Geográfica*, Barcelona.; Ariel.
Combal, B.; Baret, F.; Weiss, M.; Trubuil, A.; Mace, D.; Pragne`Re, A.; Myneni, R.; Knyazikhin, Y. y Wang, L. (2002): «Retrieval of canopy biophysical variables from bidirectional reflectance using prior information to solve the ill-posed inverse problem», *Remote Sensing of Environment*, 84: 1-15.
Conese, C.; Gilabert, M. A.; Maselli, F. y Bottai, L. (1993): «Topographic normalization of TM scenes through the use of an atmospheric correction method and digital terrain models», *Photogrammetric Engineering and Remote Sensing*, 59: 1745-1753.
Congalton, R. B. (1984): *A comparison of five sampling schemes used in assessing the accuracy of land cover/land use maps derived from remotely sensed data*, Blacksburg, Virginia Polytechnic Institute.
— (1988*a*): «A comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 54: 593-600.
— (1988*b*): «Using spatial autocorrelation analysis to explore the errors in maps generated from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 54: 587-592.
— (1991): «A review of assessing the accuracy of classifications of remotely sensed data», *Remote Sensing of Environment*, 37: 35-46.
Congalton, R. G.; Green, K. y Teply, J. (1993*a*): «Mapping old growth forests on National

forest and park lands in the Pacific Northwest from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 59: 529-535.

Congalton, R. G.; Stenback, J. M. y Barret, R. H. (1993*b*): «Mapping deer habitat suitability using remote sensing and Geographic Information Systems», *Geocarto International*, 8: 23-33.

Congalton, R. G. y Green, K. (1999): *Assessing the Accuracy of Remotely Sensed Data: Principles and Applications*, Boca Raton, Lewis Publishers.

Conway, E. D. (1997): *An Introduction to Satellite Image Interpretation*, Baltimore, John Hopkins, University Press.

Coppin, P. R. y Bauer, M. E. (1994): «Processing of multitemporal Landsat TM imagery to optimize extraction of forest cover change features», *IEEE Transactions on Geoscience and Remote Sensing*, 32: 918-927.

Coppock, J. T. y Rhind, D. W. (1991): «The History of GIS», en *Geographical Information Systems* (editado por D. J. Maguire, M. F. Goodchild y D. W. Rhind). 21-43.

Cracknell, A. P. (1997): *The Advanced Very High Resolution Radiometer (AVHRR)*, Londres, Taylor & Francis.

Cracknell, A. P. y Hayes, L. W. B. (1991): *Introduction to Remote Sensing*, Londres, Taylor & Francis.

Crapper, P. F. y Hynson, K. C. (1983): «Change detection using Landsat photographic imagery», *Remote Sensing of Environment*, 13: 291-300.

Crist, E. P. y Cicone, R. C. (1984*a*): «Application of the tasseled cap concept to simulated Thematic Mapper data», *Photogrammetric Engineering of Remote Sensing*, 50: 343-352.

— (1984*b*): «A physically-based transformation of Thematic Mapper data the TM tasseled cap», *IEEE Transactions on Geoscience and Remote Sensing*, GE22: 256-263.

Curran, P. J. (1980): «Remote Sensing systems for monitoring crops and vegetation», *Progress in Physical Geography*, 4: 315-341.

— (1981): «Multispectral remote sensing of vegetation amount», *Progress in Physical Geography*, 5: 315-341.

— (1985): *Principles of Remote Sensing*, Londres, Longman.

— (1989): «Remote Sensing of Foliar Chemistry», *Remote Sensing of Environment*, 30: 271-278.

Curran, P. J. y Foody, G. M. (1994*a*): «Environmental Issues at Regional to Global Seales», en *Enviromental Remote Sensing from Regional to Global Scales* (editado por G. M. Foody y P. J. Curran). Chichester, John Wiley & Sons: 1-7.

— (1994*b*): «The Use of Remote Sensing to Characterise the Regenerative States of Tropical Forests», en *Environmental Remote Sensing from Regional to Global Scales* (editado por Chichester, John Wiley & Sons: 44-83).

Curran, P. J.; Foody, G. M.; Kondratyev, K. Y.; Kozoderov, W. y Fedchenko, P. P. (1990): *Remote Sensing of Soils and Vegetation in the USSR*, Londres, Taylor & Francis.

Curran, P. J. y Kupiec, J. A. (1995): «Imaging spectrometry: a new tool for ecology», en *Advances in Environmental Remote Sensing* (editado por F. M. Danson y S. E. Plummer). Chichester, John Wiley & Sons: 71-88.

Cushnie, J. L. y Atkinson, P. (1985): «The effect of spatial filtering on scene noise and boundary detail in Thematic Mapper imagery», *Photogrammetric Engineering and Remote Sensing*, 51: 1483.

Cushnie, J. L. (1987): «The interactive effect of spatial resolution and degree of internal variability within land-cover types on classification accuracies», *International Journal of Remote Sensing*, 8: 15-29.

Chander, G.; Helder, D. L.; Markham, B. L.; Dewald, J. D.; Kaita, E.; Thome, K. J.; Micije-

vic, E. y Ruggles, T. A. (2004): «Landsat-5 TM reflective-band absolute radiometric calibration», *IEEE Transactions on Geoscience and Remote Sensing*, 42: 2747-2760.

Chang, A. T. C.; Fuster, J. L. y Hall, D. K. (1990): «Satellite Sensor Estimates of Northern Hemisphere Snow Volume», *International Journal of Remote Sensing*, 11: 167-171.

Chapelle, E. W.; Wood, F. W.; Mcmurtrey, J. E. y Newcomb, W. W. (1984): «Laser-induced fluorescence of green plants. 1: A technique for the remote detection of plant stress and species differentiation», *Applied Optics*, 23: 134.

Chavez, P. S. (1975): «Atmospheric, solar, and MTF corrections for ERTS digital imagery», *Proceedings of the American Society of Photogrammetry,*, Falls Church, VA.

— (1988): «An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data», *Remote Sensing of Environment*, 24: 459-479.

Chavez, P. S. y Kwarteng, A. Y. (1989): «Extracting spectral contrast in Landsat Thematic Mapper image data using selective principal component analysis», *Photogrammetric Engineering and Remote Sensing*, 55: 339-348.

Chavez, P. S.; Sides, S. C. y Anderson, J. A. (1991): «Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT Panchromatic», *Photogrammetric Engineering and Remote Sensing*, 57: 295-303.

Chavez, P. S. (1996): «Image-based atmospheric corrections. Revisited and improved», *Photogrammetric Engineering and Remote Sensing*, 62: 1025-1036.

Chen, Z.; Elvidge, C. D. y Groenveld, D. P. (1998): «Monitoring of seasonal dynamics of arid land vegetation using AVIRIS data», *Remote Sensing of Environment*, 65: 255-266.

Cheng, Y. B.; Zarco-Tejada, P. J.; Riaño, D.; Rueda, C. A. y Ustin, S. (2006): «Estimating vegetation water content with hyperspectral data for different canopy scenarios: Relationships between AVIRIS and MODIS indexes», *Remote Sensing of Environment*, 105: 354-366.

Cherniawsky, J. Y.; Foreman, M. G. G.; Crawford, W. R. y Beckley, B. D. (2004): «Altimeter observations of sea-level variability off the West Coast of North America», *International Journal of Remote Sensing*, 25: 1303-1306.

Chica, M. (1988): *Análisis Geoestadístico en el Estudio de la Explotación de los Recursos Minerales*, Granada, Universidad de Granada.

Chicharro, E. y Martínez, J. (1992): «El análisis visual de imágenes espaciales en la enseñanza de la Geografía», *Serie Geográfica*, 2: 65-80.

Chladil, M. A. y Nunez, M. (1995): «Assessing grassland moisture and biomass in Tasmania. The application of remote sensing and empirical models for a cloudy environment», *International Journal of Wildland Fire*, 5: 165-171.

Choudhury, B. J. y Nicholson, S. E. (1992): «Synergistic use of multispectral satellite data for monitoring arid lands», en *TERRA-1: Understanding the Terrestrial Environment* (editado por P. M. Mather). Londres, Taylor & Francis: 67-76.

Choudhury, B. J.; Kerr, Y. H.; Njoku, E. G. y Pampaloni, P. (eds.) (1994): *Passive Microwave Remote Sensing of Land-Atmosphere Interactions*, Utrecht, VSP BV.

Choudhury, B. J. (1997): «Global pattern of potential evaporation calculated from the Penman-Monteith equation using satellite and assimilated data», *Remote Sensing of Environment*, 61: 64-81.

Chuvieco, E. (1985*a*): «Análisis espectral, cartografía e inventario de tipos de ocupación a partir de imágenes Thematic Mapper», *Geographica*, 27: 117-129.

— (1985*b*): «Aportaciones de la teledetección espacial a la cartografía de ocupación del suelo», *Anales de Geografía de la Universidad Complutense*, 5: 29-48.

— (1986): *Análisis visual multiestacional de la ocupación del suelo en Madrid y Guadalajara: propuesta de cartografía a partir de imágenes espaciales*, Madrid, Inst. de Economía y Geografía Aplicada.

— (1992): «Teledetección, S.I.G. y Cambio Global», *Geographicalia*, 29: 33-55.
— (1998): «El factor temporal en teledetección: evolución fenológica y análisis de cambios», *Revista Española de Teledetección*, 10: 39-48.
— (ed.) (1999*a*): *Remote Sensing of Large Wildfires in the European Mediterranean Basin*, Berlin, Springer-Verlag.
— (1999*b*): «Measuring changes in landscape pattern from satellite images: short-term effects of fire on spatial diversity», *International Journal of Remote Sensing*, 20: 2331-2347.
— (ed.) (2003): *Wildland Fire Danger Estimation and Mapping. The Role of Remote Sensing Data*, Series in Remote Sensing, vol. 4, Singapur, World Scientific Publishing.
— (ed.) (2008*a*): *Earth observation of global change : the role of satellite remote sensing in monitoring global environment*, Nueva York, Springer Berlin Heidelberg.
— (2008*b*): «Satellite observation of biomass burning: implications in global change research», en *Earth Observation and Global Change* (editado por E. Chuvieco). Nueva York, Springer: 109-142.
Chuvieco, E. y Sancho, J. (1986): «Tratamiento visual y digital de las imágenes espaciales: aplicaciones docentes», *Didáctica Geográfica*, 14: 17-28.
Chuvieco, E. y Congalton, R. G. (1988): «Using cluster analysis to improve the selection of training statistics in classifying remotely sensed data», *Photogrammetric Engineering & Remote Sensing*, 54: 1275-1281.
Chuvieco, E. y Martínez Vega, J. (1990): «Visual Versus Digital Analysis for Vegetation Mapping: Some Examples on Central Spain», *Geocarto International*, 3: 21-29.
Chuvieco, E. y Martín, M. P. (1999): *Performance Assessment in the Fire Post-fire Phase. Final Report*, Alcalá de Henares, Departmento de Geografía, FOQ-132-CT-05-1a.
Chuvieco, E.; Riaño, D.; Aguado, I. y Cocero, D. (2002*a*): «Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: applications in fire danger assessment», *International Journal of Remote Sensing*, 23: 2145-2162.
Chuvieco, E.; Salas, F. J.; Meza, E. y Vargas, F. F. (2002*b*): «Empleo de la teledetección en el Análisis de la deforestación tropical: el caso de la reserva forestal de Ticoporo (Venezuela)», *Serie Geográfica*, 10: 55-76.
Chuvieco, E.; Cocero, D.; Aguado, I.; Palacios-Orueta, A. y Prado, E. (2004*a*): «Improving Burning Efficiency Estimates through Satellite Assessment of Fuel Moisture Content», *Journal of Geophysical Research - Atmospheres*, 109, D14S07, doi:10.1029/2003JD003467: 1-8.
Chuvieco, E.; Cocero, D.; Riaño, D.; Martín, M. P.; Martínez-Vega, J.; De La Riva, J. y Pérez, F. (2004b): «Combining NDVI and Surface Temperature for the estimation of live fuel moisture content in forest fire danger rating», *Remote Sensing of Environment*, 92: 322-331.
Chuvieco, E.; Ventura, G.; Martín, M. P. y Gomez, I. (2005): «Assessment of multitemporal compositing techniques of MODIS and AVHRR images for burned land mapping», *Remote Sensing of Environment*, 94: 450-462.
Chuvieco, E.; Riaño, D.; Danson, F. M. y Martín, M. P. (2006): «Use of a radiative transfer model to simulate the post-fire spectral response to burn severity», *Journal of Geophysical Research - Biosciences*, 111: doi:10.1029/2005JG000143.
Chuvieco, E.; De Santis, A.; Riaño, D. y Halligan, K. (2007): «Simulation approaches for burn severity estimation using remotely sensed images», *Journal of Fire Ecology*, 3: 129-150.
Chuvieco, E. y Justice, C. (2008): «NASA Earth Observation Satellite Missions for Global Change Research», en *Earth Observation and Global Change* (editado por E. Chuvieco). Nueva York, Springer: 23-47.

Chuvieco, E.; Englefield, P.; Trishchenko, A. P. y Luo, Y. (2008*a*): «Generation of long time series of burn area maps of the boreal forest from NOAA-AVHRR composite data», *Remote Sensing of Environment*, vol. 112: 2381-2396.

Chuvieco, E.; Giglio, L. y Justice, C. O. (2008*bp*): «Global Characterization of Fire Activity: Towards Defining Fire Regimes From Earth Observation Data», *Global Change Biology*, 14: 1488-1502.

Chuvieco, E.; Opazo, S.; Sione, W.; Del Valle, H.; Anaya, J.; Di Bella, C.; Cruz, I.; Manzo, L.; López, G.; Mari, N.; González-Alonso, F.; Morelli, F.; Setzer, A.; Csiszar, I.; Kanpandegi, J. A.; Bastarrika, A. y Libonati, R. (2008*c*): «Global Burned Land Estimation in Latin America using MODIS Composite Data», *Ecological Applications*, 18: 64-79.

Dai, X. y Khorram, S. (1998): «The effects of image misregistration on the accuracy of remotely sensed change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 36: 1566-1577.

Danjoy, W. A. y Sadowski, F. G. (1978): «Use of Landsat in the study of forest classification in the tropical jungle», *12th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor: 947-951.

Danson, F. M.; Plummer, S. E. y Briggs, S. A. (1995): «Remote Sensing and the information extraction problem», en *Advances in Environmental Remote Sensing* (editado por F. M. Danson y S. E. Plummer). Chichester, John Wiley & Sons: 171-177.

Danson, F. M. (1998): «Factors controlling vegetation canopy reflectance: a teaching model», *Photogrammetric Engineering and Remote Sensing*, 64: 809-812.

Danson, F. M. y Bowyer, P. (2004): «Estimating live fuel moisture content from remotely sensed reflectance», *Remote Sensing of Environment*, 92: 309-321.

Davis, F. W. y Simonett, D. S. (1991): «GIS and Remote Sensing», en *Geographical Information Systems* (editado por D. Maguire, M. F. Goodchild y D. W. Rhind). Londres, Longman: 191-213.

Davison, G. J. (1984): «Ground control pointing and geometric transformation of satellite imagery», *Remote Sensing Workshop on Terrestrial Positioning and Geometric Correction of Imagery*, Nottingham, Departmento de Geografía, University de Nottingham: 45-59.

De Santis, A.; Vaughan, P. y Chuvieco, E. (2006): «Foliage moisture content estimation from 1-D and 2-D spectroradiometry for fire danger assessment», *Journal of Geophysical Research - Biosciences*, 111: doi:10.1029/2005JG000149.

De Santis, A. y Chuvieco, E. (2007): «Burn severity estimation from remotely sensed data: performance of simulation versus empirical models», *Remote Sensing of Environment*, 108: 422-435.

Deane, G. C. (1980): «Preliminary evaluation of Seasat-1 SAR data for land use mapping», *Geographical Journal*, 146: 408-418.

Defries, R. S. y Townshend, J. R. G. (1994): «Global Land-Cover: Comparison of Ground-Based Data Sets to classifications with AVHRR Data», en *Environmental Remote Sensing from Regional to Global Scales* (editado por G. M. Foody y P. J. Curran). Chichester, John Wiley & Sons: 84-110.

Delbaere, B. y Gulinck, H. (1995): «A review of landscape ecological research with specific interest to landscape ecological mapping», en *Remote Sensing in landscape ecological mapping* (editado por B. Delbaere y H. Gulinck). Luxemburgo, Oficina de Publicaciones Oficiales de la Comunidad Europea: 3-28.

Desbois, N.; Deshayes, M. y Beudoin, A. (1997*a*): «Protocol for fuel moisture content measurements», en *A review of remote sensing methods for the study of large wildland fires* (editado por E. Chuvieco). Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá: 61-72.

Desbois, N.; Pereira, J. M. C.; Beuadoin, A.; Chuvieco, E. y Vidal, A. (1997*b*): «Short term fire risk mapping using remote sensing», en *A review of remote sensing methods for the study of large wildland fires* (editado por E. Chuvieco). Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá: 29-60.

Di Gregorio, A. y Jansen, L. J. M. (2000): *Land Cover Classification System (LCCS). Classification Concepts and User Manual*, Roma, FAO.

Dietrich, D. L. y Lachowski, H. M. (1978): «Identification and delineation of urbanized areas using Landsat data», *12th Inter. Symp. on Remote Sensing of Environment*, Ann Arbor: 1083-1090.

Diez De Arribas, J. M. y Nicolás, E. (2001): *Software de corrección geométrica automática de imágenes NOAA*, Departamento de Geografía, Alcalá de Henares, Univerdad de Alcalá.

Dillworth, M. E.; Whistler, J. L. y Merchant, J. W. (1994): «Measuring landscape structure using geographic and geometric windows», *Photogrammetric Engineering and Remote Sensing*, 60: 1215-1224.

Diner, D. J.; Asner, G. P.; Davies, R.; Knyazikhin, Y.; Muller, J. P.; Nolin, A. W.; Pinty, B.; Schaaf, C. y Stroeve, J. (1999): «New Directions in Earth Observing: Scientific Applications of Multiangle Remote Sensing», *Bulletin of the American Meteorological Society*, 80: 2209-2228.

Dobson, M. C. (2000): «Forest Information from Synthetic Aperture Radar», *Journal of Forestry*, 98: 41-43.

Domínguez, J. A.; Sastre, A. y Chuvieco, E. (2003): «Seguimiento del estado trófico de lagunas de gravera mediante teledetección», *Ingeniería Civil*, 131: 93-102.

Dozier, J. y Strahler, A. H. (1983): «Ground Investigations in Support of Remote Sensing», en *Manual of Remote Sensing* (editado por R. N. Colwell). Falls Church, American Society of Photogrammetry: 959-986.

Dozier, J. (1989): «Spectral Signature of Alpine Snow Cover from Landsat Thematic Mapper», *Remote Sensing of Enviroment*, 28: 9-22.

Drake, J. B. y Weishampel, J. F. (2000): «Multifractal analysis of canopy height measures in a longleaf pine savanna», *Forest Ecology and Management*, 128: 121-127.

Drury, S. A. (1998): *Images of the Earth. A guide to Remote Sensing*, Oxford, Oxford University Press.

Dubayah, R. O. y Drake, J. B. (2000): «Lidar Remote Sensing of Forestry», *Journal of Forestry*, 98: 44-46.

Duda, R. D. y Hart, P. E. (1973): *Pattern Classification and Scene Analysis*, Nueva York, John Wiley & Sons.

Duguay, C. R. y Ledrew, E. F. (1992): «Estimating surface reflectance and albedo from Landsat-5 TM over rugged terrain», *Photogrammetric Engineering and Remote Sensing*, 58: 551-558.

Dymond, J. R.; Shepherd, J. D. y Qi, J. (2001): «A simply physical model of vegetation reflectance for standardising optical satellite imagery», *Remote Sensing of Environment*, 77: 230-239.

Eastman, J. R.; Mckendry, J. y Fulk, M. (1994): *UNITAR Explorations in GIS Technology, vol. 1: Change and Time Series Analysis*, Génova, Swuiza.

Eastman, R. y Fulk, M. (1993): «Long sequence time series evaluation using standarized principal components», *Photogrammetric Engineering and Remote Sensing*, 59: 1307-1312.

Eastwood, J. A.; Plummer, S. E.; Wyatt, B. K. y Stocks, B. J. (1998): «The potential of SPOT-Vegetation data for fire scar detection in boreal forests», *International Journal of Remote Sensing*, 19: 3681-3687.

Ehleringer, J. R. y Field, C. B. (eds.) (1993): *Scaling Physiological Processes. Leaf to Globe*, San Diego, Academic Press.

Ehrlich, D.; Estes, J. E. y Sing, A. (1994): «Applications of NOAA-AVHRR 1 km. data for environmental monitoring», *International Journal of Remote Sensing*, 15: 145-161.

Eidenshink, J. (2006): «A 16-year time series of 1 km AVHRR satellite data of the conterminous United States and Alaska», *Photogrammetric Engineering and Remote Sensing*, 72: 1027-1035.

Elachi, C. (1982): «Radar images of the Earth from space», *Scientific American*, 247: 46-53.

— (1987): *Introduction to the Physics and Techniques of Remote Sensing*, Nueva York, John Wiley & Sons.

Elvidge, C. D. y Portigal, F. P. (1990): «Change detection in vegetation using AVIRIS data», *SPIE Imaging Spectroscopy of the terrestrial environment*, Orlando, FL: 178-189.

Elvidge, C. D.; Baugh, K. B.; Hobson, V. R.; Kihn, E.; Kroehl, H. W.; Davis, E. R. y Cocero, D. (1997): «Satellite inventory of human settlements using nocturnal radiation emissions: a contribution for the global toolchest», *Global Change Biology*, 3: 387-395.

Elvidge, C. D. (2001): «DMSP-OLS estimation of tropical forest area impacted by surface fires in Roraima, Brazil: 1995 versus 1998», *International Journal of Remote Sensing*, 22: 2661-2673.

Emery, W. J.; Brown, W. J. y Nowak, Z. P. (1989): «AVHRR Image Navigation: Summary and Review», *Photogrammetric Engineering and Remote Sensing*, 55: 1175-1183.

Esa (1995): *Del ERS-1 al ERS-2. Destino: la Tierra*, París, ESA-Esrin.

Estébanez, J. y Bradshaw, R. (1978): *Técnicas de Cuantificación en Geografía*, Madrid, Tebar Flores.

Estes, J. E. y Simonett, D. S. (1975): «Fundamentals of image interpretation», en *Manual of Remote Sensing* (editado por R. G. Reeves). Falls Church, American Society of Photogrammetry: 869-1076.

European Commision (1993): *Corine Land Cover: Guide Technique*, Luxemburgo, oficina de Publicaciones Oficiales en la Unión Europea.

Eyton, J. R. (1983): «Landsat multitemporal color composites», *Photogrammetric Engineering and Remote Sensing*, 49: 231-235.

Fang, H. y Liang, S. (2003): «Retrieving Leaf Area Index With a Neural Network Method: Simulation and Validation», *IEEE Transactions on Geoscience and Remote Sensing*, 41: 2052-2062.

Fernández-Gustiz, E. (2001): *Generación de Rutinas para la Detección de Cambios. Aplicación al Crecimiento Urbano de Madrid*, Departamento de Geografía, Alcalá de Henares, Universidad de Alcalá: 190.

Fernández, A.; Illera, P. y Casanova, J. L. (1997): «Automatic mapping of surfaces affected by forest fires in Spain using AVHRR NDVI composite image data», *Remote Sensing of Environment*, 60: 153-162.

Ferris, J. y Congalton, R. G. (1989): «Satellite and Geographic Information System estimates of Colorado River Basin snowpack», *Photogrammetric Engineering and Remote Sensing*, 55: 1629-1635.

Ferro, C. J. S. y Warner, T. A. (2002): «Scale and texture in digital image classification», *Photogrammetric Engineering and Remote Sensing*, 68: 51-63.

Fisher, P. F. y Pathirana, S. (1990): «The evaluation of fuzzy membership of land cover classes in the suburban zone», *Remote Sensing of Environment*, 34: 121-132.

Fitzegarld, R. W. y Lees, B. G. (1994): «Assessing the classification accuracy of multisource remote sensing data», *Remote Sensing of Environment*, 47: 362-368.

Flasse, S. P. y Ceccato, P. (1996): «A contextual algorithm for AVHRR fire detection», *International Journal of Remote Sensing*, 17: 419-424.

Florini, A. M. y Dehqanzada, Y. A. (2001): «The global politics of commercial observation satellites», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 433-448.

Foody, G. y Curran, P. (1994): *Environmental Remote Sensing from Regional to Global Scales*, Chichester, John Wiley & Sons.

Foody, G. M. (1992): «A fuzzy sets approach to the representation of vegetation continua from remotely sensed data: en example from lowland heath», *Photogrammetric Engineering and Remote Sensing*, 58: 221-225.

— (1995): «Using prior knowledge in artificial neural network classification with a minimal training set», *International Journal of Remote Sensing*, 16: 301-312.

— (2001): «Monitoring the magnitude of land-cover change around the Southern limits of the Sahara», *Photogrammetric Engineering and Remote Sensing*, 67: 841-847.

Foody, G. M. y Cox, D. P. (1994): «Sub-pixel land-cover composition estimation using a linear mixture model and fuzzy membership functions», *International Journal of Remote Sensing*, 15: 619-631.

Ford, J. P. (1980): *Seasat Views North America, the Caribbean, and Western Europe with Imaging Radar*, Pasadena, Jet Propulsion Laboratory Publications.

Fourty, T. y Baret, F. (1997): «Vegetation water and dry matter contents estimated from top-of-the atmosphere reflectance data: a simulation study», *Remote Sensing of Environment*, 61: 34-45.

Francis, P. y Jones, P. (1984): *Images of Earth*, Londres, George Phillip & Son Ltd.

Franklin, J.; Logan, T. L.; Woodcock, C. E. y Strahler, A. H. (1986): «Coniferous forest classification and inventory using Landsat and digital terrain data», *IEEE Transactions on Geoscience and Remote Sensing*, GE-24: 139-149.

Franklin, S. E. (Ed.) (2001): *Remote Sensing for Sustainable Forest Management*, Boca Raton, Fla, Lewis Publishers.

Fraser, R. H.; Li, Z. y Cihlar, J. (2000): «Hotspot and NDVI Differencing Synergy (HANDS): a new technique for burned area mapping over boreal forest», *Remote Sensing of Environment*, 74: 362-376.

Fraser, R. H.; Hall, R. J.; Landry, R.; Lynham, T.; Raymond, D.; Lee, B. y Li, Z. (2004): «Validation and calibration of Canada-wide coarse-resolution satellite burned-area maps», *Photogrammetric Engineering and Remote Sensing*, 70: 451-460.

Friedl, M. A. y Brodley, C. E. (1997): «Decision tree classification of land cover from remotely sensed data», *Remote Sensing of Environment*, 61: 399-409.

Friedl, M. A.; Brodley, C. E. y Strahler, A. H. (1999): «Maximizing land cover classification accuracies produced by decision trees at continental to global scales», *IEEE Transactions on Geoscience and Remote Sensing*, 37: 969-977.

Friedl, M. A.; Mciver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F. y Schaaf, C. (2002): «Global land cover mapping from MODIS: algorithms and early results», *Remote Sensing of Environment*, 83: 287–302.

Frohn, R. C. (1998): *Remote Sensing for Landscape Ecology. New Metric Indicators for Monitoring, Modeling and Asessment of Ecosystems*, Boca Raton, Lewis Publishers.

Fujii, T. y Fukuchi, T. (2005): *Laser Remote Sensing* Boca Raton, CRC Press.

Fuller, D. O. y Fulk, M. (2000): «Comparison of NOAA-AVHRR and DMSP-OLS for operational fire monitoring in Kalimantan, Indonesia», *International Journal of Remote Sensing*, 21: 181-187.

Fung, T. (1992): «Land Use and Land Cover Change Detection with Lansat MSS and SPOT-HRV Data in Hong Kong», *Geocarto International*, 7: 33-40.

Fung, T. y Ledrew, E. (1987): «Application of principal components analysis to change detection», *Photogrammetric Engineering and Remote Sensing*, 53: 1649-1658.

— (1988): «The determination of optimal threshold levels for change detection using various accuracy indices», *Photogrammetric Engineering and Remote Sensing*, 54: 1449-1454.

Gao, B. C. (1996): «NDWI. A normalized difference water index for remote sensing of vegetation liquid water from space», *Remote Sensing of Environment*, 58: 257-266.

García, E., Bradshaw, R. P. y Ocaña, M. C. (1986): «Análisis de los usos del suelo en la depresión de Antequera mediante la utilización del TM», *I Reunión Científica del Grupo de Trabajo en Teledetección*, Barcelona, Institut Cartografic de Catalunya: 31-50.

Garcia, M., Aguado, I. y Chuvieco, E. (2008): «Combining AVHRR and meteorological data for estimating live fuel moisture content in forest fire danger rating», *Remote Sensing of Environment*», en prensa.

Garguet-Duport, B. (1997): «Wavemerg: a multiresolution software for merging SPOT panchromatic and SPOT multispectral data», *Environmental Modeling & Software*, 12: 85-92.

Gates, D. M., Keegan, H. J., Schleter, J. C. y Weidner, V. R. (1965): «Spectral properties of plants», *Applied Optics*, 4: 11-20.

Gausman, H. W. (1977): «Reflectance of leaf components», *Remote Sensing of Environment*, 6: 1-9.

Gdta-Cee (1982): *Recherche sur la Cartographie de l'Occupation des Sols par Télédetection*, París, IGN Département de Télédetection et de Cartographie Spatiale.

Gibson, P. y Power, C. H. (2000*a*): *Introductory Remote Sensing: Digital Image Processing and Applications*, Londres, Routledge.

— (2000*b*): *Introductory Remote Sensing: Principles and Concepts*, Londres, Routledge.

Giglio, L., Descloitres, J., Justice, C. O. y Kaufman, Y. J. (2003): «An Enhanced Contextual Fire Detection Algorithm for MODIS», *Remote Sensing of Environment*, 87: 273-282.

Gilabert, M. A., Conese, C. y Maselli, F. (1994): «An atmospheric correction method for the automatic retrieval of surface reflectances from TM images», *International Journal of Remote Sensing*, 15: 2065-2086.

Ginevan, M. E. (1979): «Testing land-use map accuracy: another look», *Photogrammetric Engineering and Remote Sensing*, 45: 1371-1377.

Gitas, I. Z., Mitri, G. H. y Ventura, G. (2004): «Object-based image classification for burned area mapping of Creus Cape, Spain, using NOAA-AVHRR imagery», *Remote Sensing of Environment*, 92: 409-413.

Goel, N. S. (1988): «Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data», *Remote Sensing Reviews*, 4: 1-212.

Goetz, S., Fiske, G. y Bunn, A. (2006): «Using satellite time-series data sets to analyze fire disturbance and forest recovery across Canada», *Remote Sensing of Environment*, 92: 411-423.

Gogineni, S., Ampe, J. y Budihardjo, A. (1991): «Radar Estimates of Soil Moisture Over the Konza Prairie», *International Journal of Remote Sensing*, 12: 2425-2432.

Gómez-Delgado, M. y Barredo-Cano, J. I. (2006): *Sistemas de informacion geografica y evaluacion multicriterio en la ordenacion del territorio*, Madrid, RA-MA.

Gong, P. (1994): «Integrated analysis of spatial data from multiple sources: an overview», *Canadian Journal of Remote Sensing*, 20: 349-359.

— (1996): «Integrated analysis of spatial data from multiple sources: using evidential reasoning and artificial neural network techniques for geological mapping», *Photogrammetric Engineering and Remote Sensing*, 62: 513-523.

Gong, P. y Howarth, P. J. (1990*a*): «An assessment of some factors influencing multispectral

land-cover classification», *Photogrammetric Engineering and Remote Sensing*, 56: 597-603.

— (1990*b*): «The use of structural information for improving land-cover classification accuracies at the rural-urban fringe. *Remote Sensing of Environment*, 56: 67-73.

Gong, P., Marceau, O. J. y Howarth, P. J. (1992): «A comparison of spatial feature extraction algorithms for land-use classification with SPOT-HRV data», *Remote Sensing of Environment*, 40: 137-151.

Gong, P., Miller, J. R. y Spanner, M. (1994): «Forest canopy closure from classification and spectral unmixing of scene components. Multisensor evaluation of an open canopy», *IEEE Transactions on Geoscience and Remote Sensing*, 32: 1067-1079.

Gong, P.; Pu, R. L., Li, Z. Q., Scarborough, J., Clinton, N. y Levien, L. M. (2006): «An integrated approach to wildland fire mapping of California, USA using NOAA/AVHRR data», *Photogrammetric Engineering and Remote Sensing*, 72: 139-150.

González-Alonso, F.; Cuevas, J. M.; Calle, A.; Casanova, J. L. y Romo, A. (2004): «Spanish vegetation monitoring during the period 1987-2001 using NOAA-AVHRR images», *International Journal of Remote Sensing*, 25: 3-6.

González, F. y López, S. (1991): «Using contextual information to improve land use classification of satellite images in Central Spain», *International Journal of Remote Sensing*, 12: 2227-2235.

Gonzalez, R. C. y Wintz, P. (1977): *Digital Image Processing*, Reading, Mass., Addison & Wesley.

Goodenough, D. G.; Dyk, A.; Niemann, K. O.; Pearlman, J. S.; Chen, H.; Han, T.; Murdoch, M. y West, C. (2003): «Processing Hyperion and ALI for forest classification», *IEEE Transactions on Geoscience and Remote Sensing*, 41: 1321- 1331.

Gopal, S. y Woodcock, C. (1996): «Remote sensing of forest change using artificial neural networks», *IEEE Transactions on Geoscience and Remote Sensing*, 34: 398-404.

Gordon, D. K. y Philipson, R. (1986): «A texture-enhancement procedure for separating orchard from forest in Thematic Mapper data», *International Journal of Remote Sensing*, 7: 301-304.

Gordon, S. I. (1980): «Utilizing Landsat imagery to monitor land use change: a case study in Ohio», *Remote Sensing of Environment*, 9: 189-196.

Gors (1996): *Syria. Space Image Atlas*, Damasco, General Organization of Remote Sensing.

Goward, S.; Arvldson, T.; Williams, D.; Faundeen, J.; Irons, J. y Franks, S. (2006): «Historical record of landsat global coverage: Mission operations, NSLRSDA, and international cooperator stations», *Photogrammetric Engineering and Remote Sensing*, 72: 1155-1169.

Goward, S. N.; Markham, B.; Dye, D. G.; Dulaney, W. y Yang, I. (1991): «Normalized difference vegetation index measurements from the Advanced Very High Resolution Radiometer», *Remote Sensing of Environment*, 35: 257-277.

Goward, S. N. y Skole, D. (2005): «Landsat 2005:Time to Act», *Space News*, October 31.

Gower, J. F. R. (Ed.) (1994): *Oceanography from Space*, Plenum Press.

Green, A. A.; Berman, M.; Switzer, P. y Craig, M. D. (1988): «A transformation for ordering multispectral data in terms of image quality with implications for noise removal», *IEEE Transactions on Geoscience and Remote Sensing*, 26: 65-74.

Green, K. (1994): «The potential and limitations of remote sensing and GIS providing ecological information», en *Remote Sensing and GIS in Ecosystem Management* (editado por V. A. Sample). Washington D. C., Island Press: 327-336.

— (2000): «Selecting and interpreting high-resolution images», *Journal of Forestry*, 98: 37-39.

Griffiths, G. H.; Smith, J. M.; Veitch, N. y Aspinall, R. (1993): «The ecological interpreta-

tion of satellite imagery with special reference to Bird Habitats», en *Landscape Ecology and Geographic Information Systems* (editado por R. Haines-Young, D. R. Green y S. Cousins). Londres, Taylor & Francis: 255-272.

Grover, K. D.; Quegan, S.; Yanasse, C. C. F. y Dutra, L. V. (1995): «Potencial Use of ERS-1 in Tropical Forest Monitoring. A study of the Tepajos National Forest, Brazil», *Earth Observation Quarterly*, 48: 12-15.

Gulinck, H.; Walpot, D.; Janssens, P. y Dries, I. (1991): «The visualization of corridors in the landscape using SPOT data», en *Nature Conservation 2: The role of corridors* (editado por D. Saunders y R. J. Hobbs). Surrey, Beatty & Sons: 9-17.

Gurney, C. M. y Townshend, J. R. G. (1983): «The use of contextual information in the classification of remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 49: 55-64.

Gutiérrez, J. y Gould, M. (1994): *S.I.G.: Sistemas de Información Geográfica*, Madrid, Síntesis.

Gutman, G. G. (1994): «Global data on land surface parameters from NOAA-AVHRR for use in numerical climate model», *Journal of Climate*, 7: 669-680.

Guyot, G.; Guyon, D. y Riom, J. (1989): «Factors affecting the spectral response of forest canopies: a review», *Geocarto International*, 4: 3-18.

Guyot, G. y Gu, X. F. (1994): «Effect of radiometric corrections on NDVI determined from SPOT-HRV and Landsat-TM data», *Remote Sensing of Environment*, 49: 169-180.

Haack, B.; Bryant, N. y Adams, S. (1987): «An assessment of Landsat MSS and TM data for urban and near-urban land-cover digital classification», *Remote Sensing of Environment*, 21: 201-213.

Haines-Young, R.; Green, D. R. y Cousins, S. H. (eds.) (1993): *Landscape Ecology and Geographic Information Systems*, Londres, Taylor & Francis.

Hall, D. K. y Martinec, J. (1985): *Remote Sensing of Ice and Snow*, Londres, Chapman and Hall.

Hall, D. K. (1988): «Assessment of Polar climate change using satellite technology», *Reviews of Geophysics*, 26: 26-39.

Hall, F. G.; Botkin, D. B.; Strebel, D. E.; Woods, K. D. y Goetz, S. J. (1991*a*): «Large-scale patterns of forest succession as determined by remote sensing», *Ecology*, 72: 628-640.

Hall, F. G.; Strebel, D. E.; Nickeson, E. y Goetz, S. J. (1991*b*): «Radiometric rectification: toward a common radiometric response among multidate multisensor images», *Remote Sensing of Environment*, 35: 11-27.

Hammill, K. A. y Bradstock, R. A. (2006): «Remote sensing of fire severity in the Blue Mountains: influence of vegetation type and inferring fire intensity», *International Journal of Wildland Fire*, 15: 213-226.

Hand, D. J. (1981): *Discrimination and Classification*, Nueva York, John Wiley & Sons.

Hansen, M.; Dubayah, R. y Defries, R. (1996): «Classification trees: an alternative to traditional land cover classifiers», *International Journal of Remote Sensing*, 17: 1075-1081.

Hansen, M. C., Townshend, J. R. G.; Defries, R. S. y Carroll, M. (2005): «Estimation of tree cover using MODIS data at global, continental and regional/local scales», *International Journal of Remote Sensing*, 26: 4359-4380.

Haralick, R. M.; Shanmugan, K. y Dinstein, I. (1973): «Textural features for image classification», *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3: 610-621.

Harding, D. J. y Carabajal, C. C. (2005): «ICESat waveform measurements of within-footprint topographic relief and vegetation vertical structure», *Geophysical Research Letters*, 32: doi:10.1029/2005GL023471, 4 páginas.

Hardy, C. C. y Burgan, R. E. (1999): «Evaluation of NDVI for monitoring live moisture in three vegetation types of the Western U.S.», *Photogrammetric Engineering and Remote Sensing*, 65: 603-610.

Hargrove, W. W.; Gardner, R. H.; Turner, M. G.; Romme, W. H. y Despain, D. G. (2000): «Simulating fire patterns in heterogeneous landscapes», *Ecological Modelling*, 135: 243-263.

Harnapp, V. (1978): «Landsat imagery: a tool for updating land use in Gulf Coast Mexico», *Journal of Geography*, 78: 141-144.

Harper, D. (1983): *Eye in the Sky. Introduction to Remote Sensing*, Montreal, Multiscience Publications Ltd.

Harris, R. (1987): *Satellite Remote Sensing. An Introduction*, Londres, Routledge & Kegan Paul.

Hart, W. G. (1975): «The use of Skylab data to study the early detection of insect infestations and density and distribution of host plants», *NASA Earth Resources Survey Symposium*: 203-220.

Hay, A. M. (1979): «Sampling designs to test land-use map accuracy», *Photogrammetric Engineering and Remote Sensing*, 45: 529-533.

— (1988): «The derivation of global estimates from a confusion matrix», *International Journal of Remote Sensing*, 9: 1385-1398.

Hazel, G. G. (2001): «Object-Level Change Detection in Spectral Imagery», *IEEE Transactions on Geoscience and Remote Sensing*, 39: 553-561.

Henderson, F. M. y Lewis, A. J. (eds.) (1998): *Principals and Applications of Imaging Radar*, Manual of Remote Sensing, Nueva York, John Wiley & Sons, Inc.

Henebry, G. M. (1993): «Detecting change in grasslands using measures of spatial dependence with Landsat-TM data», *Remote Sensing of Environment*, 46: 223-234.

Heo, J. y Fitzhugh, T. W. (2000): «A standardized radiometric normalization method for change detection using remotely sensed imagery», *Photogrammetric Engineering and Remote Sensing*, 66: 173-181.

Hepner, G.; Logan, T.; Ritter, N. y Bryant, N. (1990): «Artificial neural network classification using a minimal training set: comparison to conventional supervised classification», *Photogrammetric Engineering and Remote Sensing*, 56: 469-473.

Heric, M.; Lucas, C. y Devine, C. (1996): «The Open Skies Treaty: qualitative utility evaluations of aircraft reconnaissance and commercial satellite imagery», *Photogrammetric Engineering and Remote Sensing*, 62: 279-284.

Herrera, V. (2001): «Estudio del crecimiento urbano de la ciudad de Valdivia (Chile) a través del uso integrado de imágenes de satélite, SIG y equipos GPS», *Revista Española de Teledetección*, 15: 69-78.

Hervás, J. (1987): «La utilidad de análisis de componentes principales en cartografía litológica. Su aplicación a imágenes Landsat-TM y MSS del macizo ultrabásico de Ronda», *II Reunión Nac. Grupo Trabajo Teledetección*, Valencia: 50-52.

Hervás, J. y Rosin, P. L. (2001): «Tratamiento digital de imágenes de teledetección en el espectro óptico para el reconocimiento y control de deslizamientos», *V Simposio Nacional sobre Taludes y Laderas Inestables*, Madrid, CEDEX, Ministerio de Fomento: 63-74.

Hewitson, B. C. y Crane, R. G. (eds.) (1994): *Neural Nets: Applications in Geography*, Dordrecht, Kluwer Academic Publishers.

Hilwig, F. W. (1980): «Visual interpretation of multitemporal Landsat data for inventories of natural resources», *ITC Journal*, 2: 297-327.

Hill, J. y Sturm, B. (1991): «Radiometric correction of multitemporal Thematic Mapper data for use in agricultural land-cover classification and vegetation monitoring», *International Journal of Remote Sensing*, 12: 1471-1491.

Hixson, M.; Scholz, D.; Fuhs, N. y Akiyama, T. (1980): «Evaluation of several schemes for classification of remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 46: 1547-1553.

Hlavka, C. A. y Spanner, M. A. (1995): «Unmixing AVHRR imagery to assess clearcuts and forest regrowth in Oregon», *IEEE Transactions on Geoscience and Remote Sensing*, 33: 788-795.

Ho, D. y Asem, A. (1986): «NOAA AVHRR image referencing», *International Journal of Remote Sensing*, 7: 895-904.

Hobbs, R. J. y Mooney, H. A. (1990): *Remote Sensing of Biosphere Functioning*, Nueva York, Springer-Verlag.

Hoffer, R. M. (1994): «Challenges in developing and applying remote sensing to ecosystem management», en *Remote Sensing and GIS in Ecosystem Management* (editado por V. A. Sample). Washington D. C., Island Press: 25-40.

Hoffer, R. M. y Fleming, M. D. (1978): *Mapping vegetative cover by computer-aided analysis of satellite data*, Purdue, LARS, Technical Report 011178.

Hoffer, R. M. y Swain, P. H. (1980): «Computer processing of satellite data for assessing agriculture, forest, and rangeland resources», *14th Intern. Soc. of Photog.*, Hamburgo: 437-446.

Holben, B. y Justice, C. (1981): «An examination of spectral band ratioing to reduce the topographic effect on remotely sensed data», *International Journal of Remote Sensing*, 2: 115-133.

Holben, B. N. (1980): «Spectral assessment of soybean leaf area and leaf biomass», *Photogrammetric Engineering and Remote Sensing*, 46: 651-656.

— (1986): «Characteristics of maximum-value composite images from temporal AVHRR data», *International Journal of Remote Sensing*, 7: 1417-1434.

Holben, B. N. y Shimabukuro, Y. E. (1993): «Linear mixing model applied to coarse spatial resolution data from multispectral satellite sensors», *International Journal of Remote Sensing*, 14: 2231-2240.

Holz, R. K. (Ed.) (1973): *The Surveillant Science. Remote Sensing of the Environment*, Boston, Houghton Mifflin Company.

Hopkins, P. F.; Maclean, A. L. y Lillesand, T. M. (1988): «Assessments of Thematic Mapper imagery for forestry applications under lake states conditions», *Photogrammetric Engineering and Remote Sensing*, 54: 61-68.

Hord, R. M. (1982): *Digital Image Processing of Remotely Sensed Data*, Nueva York, Academic Press.

— (1986): *Remote Sensing. Methods and Applications*, Nueva York, John Wiley & Sons.

Hord, R. M. y Brooner, W. (1976): «Land use map accuracy criteria», *Photogrammetric Engineering and Remote Sensing*, 42: 671-677.

Horler, D. N. H.; Dockray, M. y Barber, J. (1983): «The red edge of plant leaf reflectance», *International Journal of Remote Sensing*, 4: 273-288.

Hosgood, B.; Jacquemoud, S.; Andreoli, G.; Verdebout, J.; Pedrini, G. y Schmuck, G. (1994): *Leaf Optical Properties EXperiment 93 (LOPEX93)*, European Commission, Joint Research Centre, Institute for Remote Sensing Applications, Report EUR 16095 EN.

Howard, J. A. (1991): *Remote Sensing of Forest Resources*, Londres, Chapman & Hall.

Howarth, P. J. y Wickware, G. M. (1981): «Procedures for change detection using Landsat digital data», *International Journal of Remote Sensing*, 2: 277-291.

Howarth, P. J. y Boasson, E. (1983): «Landsat digital enhancements for change detection in urban environments», *Remote Sensing of Environment*, 13: 149-169.

Hudson, W. D. y Ramn, C. W. (1987): «Correct formulation of the kappa coefficient of agreement», *Photogrammetric Engineering and Remote Sensing*, 53: 421-422.

Huemmrich, K. F. (2001): «The GeoSail model: a simple addition to the SAIL model to describe discontinuous canopy reflectance», *Remote Sensing of Environment*, 75: 423-431.

Huete, A.; Justice, C. y Liu, H. (1994): «Development of vegetation and soil indices for MODIS-EOS», *Remote Sensing of Environment*, 49: 224-234.

Huete, A.; Didan, K.; Miura, T.; Rodriguez, E. P.; Gao, X. y Ferreira, L. G. (2002): «Overview of the radiometric and biophysical performance of the MODIS vegetation indices», *Remote Sensing of Environment*, 83: 195-213.

Huete, A. R. (1987): «Spectral signatures and vegetation indices», *II Reunión Nacional del Grupo de Trabajo en Teledetección*, Valencia, Asociación Española de Teledetección: 13-26.

— (1988): «A soil-adjusted vegetation index (SAVI)», *Remote Sensing of Environment*, 25: 295-309.

Huete, A. R.; Hua, G.; Qi, J.; Chehbouni, A. y Van Leeuwen, W. J. D. (1992): «Normalization of Multidirectional Red and NIR reflectances with the SAVI», *Remote Sensing of Environment*, 41: 143-154.

Huffaker, R. M.; Lawrence, T. R.; Post, M. J.; Priestley, J. T.; Hall, F. F.; Richter, R. A. y Keller, R. J. (1984): «Feasibility studies for a global wind measuring satellite system (Wyndsat). Analysis of simulated performance», *Applied Optics*, 23: 2523-2534.

Hunt, E. R. y Rock, B. N. (1989): «Detection of changes in leaf water content using near and middle-infrared reflectances», *Remote Sensing of Environment*, 30: 43-54.

Hunt, E. R.; Rock, B. N. y Nobel, P. S. (1987): «Measurement of leaf relative water content by infrared reflectance», *Remote Sensing of Environment*, 22: 429-435.

Hutchinson, C. F. (1982): «Techniques for combining Landsat and ancillary data for digital classification improvement», *Photogrammetric Engineering and Remote Sensing*, 48: 123-130.

Hyyppa, J. y Hallikainen, M. (1996): «Applicability of Airborne Profiling Radar to Forest Inventory», *Remote Sensing of Environment*, 57: 39-57.

Illera, P.; Fernández, A. y Delgado, J. A. (1996): «Temporal evolution of the NDVI as an indicator of forest fire danger», *International Journal of Remote Sensing*, 17: 1093-1105.

Ingebritsen, S. E. y Lyon, R. J. P. (1985): «Principal components analysis of multitemporal image pairs», *International Journal of Remote Sensing*, 6: 687-695.

Irons, J. R. y Kennard, R. L. (1986): «The utility of Thematic Mapper sensor characteristics for surface mine monitoring», *Photogrammetric Engineering and Remote Sensing*, 52: 389-396.

Itten, K. I. y Meyer, P. (1993): «Geometric and Radiometric Correction of TM Data of Mountainous Forested Areas», *IEEE Transactions on Geoscience and Remote Sensing*, 31: 764-770.

Iverson, L. R.; Cook, E. A. y Graham, R. L. (1989): «A technique for extrapolating and validating forest cover across large regions. Calibrating AVHRR data with TM data», *International Journal of Remote Sensing*, 10: 1805-1812.

Jackson, R. D. y Ezra, C. E. (1985): «Spectral response of cotton to suddenly induced water stress», *International Journal Remote Sensing*, 6: 177-185.

Jackson, R. D.; Pinter, P. J.; Reginato, R. J. y Idso, S. B. (1986): «Detection and evaluation of plant stress for crop management decisions», *IEEE Transactions on Geoscience and Remote Sensing*, 24: 99-106.

Jacquemoud, S. (1990): «PROSPECT: a model to leaf optical properties spectra», *Remote Sensing of Environment*, 34: 74-91.

— (1993): «Inversion of the PROSPECT+SAIL canopy reflectance model from AVIRIS equivalent spectra: theoretical study», *Remote Sensing of Environment*, 44: 281-292.

Jacquemoud, S.; Bacour, C.; Poilve, H. y Frangi, J. P. (2000): «Comparison of Four Radiative Transfer Models to Simulate Plant Canopies Reflectance: Direct and Inverse Mode», *Remote Sensing of Environment*, 74: 471-481.

Jakubauskas, M. E.; Lulla, K. P. y Mausel, P. W. (1990): «Assessment of vegetation change in a fire-altered forest landscape», *Photogrammetric Engineering and Remote Sensing*, 56: 371-377.

Jensen, J. R. (1996): *Introductory Digital Image Processing. A Remote Sensing Perspective*, Upper Saddle River N.J., Prentice-Hall.

— (2000): *Remote Sensing of the Environment. An Earth Resource Perspective*, Upper Saddle River N. J., Prentice-Hall.

Jensen, J. R. y Al.; E. (1983): «Urban/Suburban land use analysis», en *Manual of Remote Sensing* (editado por R. N. Colwell). Falls Church, American Society of Photogrammetry: 1571-1666.

Ji, W.; Civco, D. L. y Kennard, W. C. (1992): «Satellite remote bathymetry: a new mechanism for modelling», *Photogrammetric Engineering and Remote Sensing*, 58: 545-549.

Jin, S. y Sader, S. (2005): «MODIS time-series imagery for forest disturbance detection and quantification of patch size effects», *Remote Sensing of Environment*, 99: 462-470.

Johnston, R. J. (1978): *Multivariate Statistical Analysis in Geography*, Londres, Longman.

Joly, G.; Verger, F. y Crettez, J. P. (1983): «Classification des donées Landsat unitemporelles et multitemporelles par la transformation de Karhunen-Loève. Application à l'Anse de l'Aiguillon», *L'Espace Géographique*, 2: 125-141.

Juppenlatz, M. y Tian, X. (1996): *Geographic Information Systems and Remote Sensing: guidelines for use by planners and decision makers*, Roseville, Australia, McGraw-Hill.

Justice, C. O. y Townshend, J. R. G. (1981): «The use of Landsat data for land cover inventories of Mediterranean lands», en *Terrain Analysis and Remote Sensing* (editado por J. R. G. Townshend). Londres, George Allen & Unwin: 135-153.

Justice, C. O.; Townshend, J. R. G.; Vermote, E. F.; Masuoka, E.; Wolfe, R. E.; Saleous, N.; Roy, D. P. y Morisette, J. T. (2002): «An overview of MODIS Land data processing and product status», *Remote Sensing of Environment*, 83: 3-15.

Kasischke, E. S.; French, N. H. F.; Harrell, P.; Christensen, N. L.; Ustin, S. L. y Barry, D. (1993): «Monitoring of wildfires in Boreal Forests using large area AVHRR NDVI composite image data», *Remote Sensing of Environment*, 45: 61-71.

Kaufman, Y. y Tanré, D. (1992): «Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS», *IEEE Transactions on Geoscience and Remote Sensing*, 30: 261-270.

Kaufman, Y. J.; Fraser, R. S. y Ferrare, R. A. (1990): «Satellite measurements of large-scale air pollution: methods», *Journal of Geophysical Research*, 95: 9895-9909.

Kauth, R. J. y Thomas, G. S. (1976): «The Tasseled Cap. A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat», *Symp. on Machine Processing of Remotely Sensed Data*, Purdue: 41-51.

Kelly, R. y Hall, D. K. (2008): «Remote sensing of terrestrial snow and ice for global change studies», en *Earth Observation and Global Change* (editado por E. Chuvieco). Springer-Verlag: 189-220.

Kennedy, P. (1989): «Monitoring the vegetation of Tunisian grazing lands using the Normalized Difference Vegetation Index», *Ambio*, 18: 119-123.

Kennedy, P. J.; Belward, A. S. y Grégoire, J. M. (1994): «An improved approach to fire monitoring in West Africa using AVHRR data», *International Journal of Remote Sensing*, 15: 2235-2255.

Kerdiles, H. y Grondona, M. O. (1995): «NOAA-AVHRR NDVI decomposition and subpixel classification using linear mixing in the Argentinean Pampa», *International Journal of Remote Sensing*, 95: 1303-1325.

Kerr, Y. H.; Lagouarde, J. P. y Imbernon, J. (1992): «Accurate land surface temperature retrieval from AVHRR data with use of an improved Split Window algorithm», *Remote Sensing of Environment*, 41: 197-209.

Ketting, R. L. y Landgrebe, D. A. (1975): «Classification of multispectral image data by extraction and classification of homogeneous objects», *Symposium on Machine Classification of Remotely Sensed Data*, West Lafayette: 1-11.

Khlopenkov, K. V. y Trishchenko, A. P. (2007): «SPARC: New cloud, snow, and cloud shadow detection scheme for historical 1-km AVHHR data over Canada», *Journal of Atmospheric and Oceanic Technology*, 24: 322-343.

Kidwell, K. B. (1990): *Global Vegetation Index. User's guide*, Washington, D. C, NOAA/ NESDIS/NCDC.

— (1991): *NOAA Polar Orbiter Data (TIROS-N, NOAA-6, NOAA-7, NOAA-8, NOAA-9, NOAA-10, NOAA-11, and NOAA-12). Users Guide*, Washington, D. C., NOAA/ NESDIS,

Kiefer, R. W. (1988): *Survey of Photogrammetry and Remote Sensing Programs and Courses in the United States and Canada*, Falls Church, American Society of Photogrammetry and Remote Sensing.

King, M. D.; Kaufman, Y. J.; Tanré, D. y Nakajima, T. (1999): «Remote Sensing of Troposheric Aerosols from Space: Past, Present and Future», *Bulletin of the American Meteorological Society*, 80: 2229-2259.

King, R. B. (1981): «An evaluation of Landsat-3 RBV imagery for obtaining environmental information in Tanzania», *Matching Remote Sensing Technologies and their Applications*, Londres, Remote Sensing Society: 85-95.

Knipling, E. B. (1970): «Physical and Physiological basis for the reflectance of visible and near-infrared radiation from vegetation», *Remote Sensing of Environment*, 1: 155-159.

Kobayashi, T. (1987): «Techniques for laser remote sensing of the environment», *Remote Sensing Reviews*, 3: 1-57.

Koetz, B.; Baret, F.; Poilvé, H.; Hill, J. (2005): «Use of coupled canopy structure dynamic and radiative transfer models to estimate biophysical canopy characteristics», *Remote Sensing of Environment*, 95: 115-124.

Kogan, F. N. (1990): «Remote sensing of weather impacts on vegetation in non-homogeneous areas», *International Journal of Remote Sensing*, 11: 1405-1419.

Konecny, G. (1986): «First Results of the European Spacelab Photogrammetric Camera Mission», en *Satellite Remote Sensing for Resources Development* (editado por K. H. Szekielda). Londres, Graham & Trotman Ltd.: 115-121.

Koopmans, B. N. (1983): «Spaceborne imaging radars, present and future», *ITC Journal*, 83: 223-231.

Korontzi, S.; Mccarty, J.; Loboda, T.; Kumar, S. y Justice, C. O. (2006): «Global distribution of agricultural fires in croplands from 3 years of Moderate Resolution Imaging Spectroradiometer (MODIS) data», *Global Biogeochemical Cycles*, 20: GB2021, doi:10.1029/ 2005GB002529.

Koutsias, N. y Karteris, M. (1998): «Logistic regression modelling of multitemporal Thematic Mapper data for burned area mapping», *International Journal of Remote Sensing*, 19: 3499-3514.

Koutsias, N.; Karteris, M. y Chuvieco, E. (2000): «The use of intensity-hue-saturation transformation of Landsat-5 Thematic Mapper data for burned land mapping», *Photogrammetric Engineering and Remote Sensing*, 66: 829-839.

Kramer, H. J. (2002): *Observation of the Earth and its Environment. Survey and Missions and Sensors*, Berlin, Springer-Verlag.

Krasnopolsky, V. M. y Breaker, L. C. (1994): «The problem of AVHRR image navigation revisited», *International Journal of Remote Sensing*, 15: 979-1008.

Kruse, F. A. (2004): «Comparison of ATREM, ACORN, and FLAASH atmospheric corrections using low-altitude AVIRIS data of boulder, Colorado», *Proceedings 13th JPL Airborne Geoscience Workshop*, Pasadena, CA.

Kruse, F. A.; Lefkoff, A. B.; Boardman, J. B.; Heidebrecht, K. B.; Shapiro, A. T.; Barloon, P. J. y Goetz, A. F. H. (1993*a*): «The Spectral Image Processing (SIPS) - Interactive Visualization and Analysis of Imaging Specrometer Data», *Remote Sensing of Environment*, 44: 145-163.

Kruse, F. A.; Lefkoff, A. B. y Dietz, J. B. (1993*b*): «Expert System-Based Mineral Mapping in Northern Death Valley, California/Nevada, using the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)», *Remote Sensing of Environment*, 44: 309-336.

Kumar, R. y Silva, L. F. (1977): «Separability of agricultural covert types by remote sensing in the visible and infrared wavelength regions», *IEEE Transactions on Geoscience Electronics*, 15: 49-59.

Kuusk, A. (2001): «A two-layer canopy reflectance model», *Journal of Quantitative Spectroscopy and Radiative Transfer*, 71: 1-9.

Labrandero, J. L. (1978): *Aplicación de métodos digitales al reconocimiento de suelos mediante sensores remotos*, Departamento de Geología, Madrid, Universidad Autónoma de Madrid.

Labuto, M. R. (1991): «Cloud detection using "yellowness" parameter from "tasseled cap" transformation in a Landsat-MSS image», *V Simp. Latinoam. de Percepción Remota*, Cuzco: 220-228.

Lachowski, H.; Maus, P. y Platt, B. (1992): «Integrating remote sensing with GIS. Procedures from the forest service», *Journal of Forestry*, 90: 16-21.

Lam, N. S. (1990): «Description and measurement of Landsat-TM images using fractals», *Photogrammetric Engineering and Remote Sensing*, 56: 187-195.

Lambin, E. F. y Geist, H. (eds.) (2006): *Land-use and land-cover change: local processes and global impacts*, Berlin, Springer.

Latifovic, R.; Zhu, Z. L.; Cihlar, J.; Giri, C. y Olthof, I. (2004): «Land cover mapping of north and central America - Global Land Cover 2000», *Remote Sensing of Environment*, 89: 116-127.

Latifovic, R.; Trishchenko, A. P.; Chen, J.; Park, W. B.; Khlopenkov, K. V.; Fernandes, R.; Pouliot, D.; Ungureanu, C.; Luo, Y.; Wang, S.; Davidson, A. y Cihlar, J. (2005): «Generating historical AVHRR 1 km baseline satellite data records over Canada suitable for climate change studies», *Canadian Journal of Remote Sensing*, 31: 324-346.

Lauer, D. T.; Estes, J. E.; Jensen, J. R. y Greenlee, D. D. (1991): «Institutional issues affecting the integration and use of remotely sensed data and geographic information systems», *Photogrammetric Engineering and Remote Sensing*, 57: 647-654.

Leblon, B. (2001): «Forest Wildfire Hazard Monitoring Using Remote Sensing: A Review», *Remote Sensing Reviews*, 20: 1-57.

Leblon, B.; Kasischke, E. S.; Alexander, M. E.; Doyle, M. y Abbott, M. (2002): «Fire danger monitoring using ERS-1 SAR images in the case of northern boreal forests», *Natural Hazards* 27: 231-255.

Leckie, D. G. (1990): «Synergism of synthetic aperture radar and visible/infrared data for forest type discrimination», *Photogrammetric Engineering and Remote Sensing*, 56: 1237-1246.

Lee, T.; Richards, J. A. y Swain, P. H. (1987): «Probabilistic and evidential approaches for multisource data analysis», *IEEE Transactions on Geoscience and Remote Sensing*, 25: 283-292.

Lefsky, M. A.; Cohen, W. B.; Acker, S. A.; Parker, G. G.; Spies, T. A. y Harding, D. (1999): «Lidar remote sensing of the canopy structure and biophysical properties of Douglas-fir western hemlock forests», *Remote Sensing of Environment*, 70: 339-361.

Leghorn, R. S. y Herken, G. (2001): «The origins and evolution of openness in overhead global observations», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 17-36.

Leprieur, C.; Kerr, Y. H.; Mastorchio, S. y Meunier, J. C. (2000): «Monitoring vegetation cover across semi-arid regions: comparison of remote observations from various scales», *International Journal of Remote Sensing*, 21: 281-300.

Lewis, A. J.; Henderson, F. M. y Holcomb, D. W. (1998): «Radar Fundamentals: The Geoscience Perspective», en *Principals and Applications of Imaging Radar* (editado por F. M. Henderson y A. J. Lewis). Nueva York, John Wiley & Sons, Inc.: 131-182.

Li, H. y Reynolds, J. F. (1993): «A new contagion index to quantify spatial patterns of landscapes», *Landscape Ecology*, 8: 155-162.

Li, X. y Strahler, A. H. (1986): «Geometric-optical bidirectional reflectance modeling of a conifer forest canopy», *IEEE Transactions on Geoscience and Remote Sensing*, 24: 906-919.

Liang, S. (2004): *Quantitative remote sensing for land surface characterization*, Hoboken, Nueva Jersey, Wiley.

Lillesand, T. M. y Kiefer, R. W. (2000): *Remote Sensing and Image Interpretation*, Nueva York, John Wiley & Sons.

Linden, D. S. (2000): «Videography for Foresters», *Journal of Forestry*, 98: 25-27.

Links, H. F. (1976): «Land-use mapping from Skylab S190B photography», *Photogrammetric Engineering and Remote Sensing*, 42: 301-307.

Lo, C. P. (1986): *Applied Remote Sensing*, Nueva York, Logman Scientific and Technical.

Lo, C. P. y Welch, R. (1977): «Chinese urban population estimates», *Annals Association of American Geographers*, 47: 246-253.

Lo, T. H. C.; Scarpace, F. L. y Lillesand, T. M. (1986): «Use of multitemporal spectral profiles in agricultural land-cover classification», *Photogrammetric Engineering and Remote Sensing*, 52: 535-544.

Lobo, A. (1997): «Image Segmentation and Discriminant Analysis for the Identification of Land Cover Units in Ecology», *IEEE Transactions on Geoscience and Remote Sensing*, 35: 1136-1145.

López-Baeza, E. (1991): «Climatología desde satélites», en *La Teledetección en el Seguimiento de los Fenómenos Naturales. Recursos Renovables: Agricultura* (editado por G. S. y J. Meliá). Valencia, Universitat de València, Departament de Termodinámica: 325-344.

López, M. J. (1991): *La temperatura del mar balear a partir de imágenes de satélite*, Departamento de Geografía, Valencia, Universitat de València: 158.

López, M. J. y Caselles, V. (1989): «A multitemporal study of chlorophyll A concentration in the Albufera lagoon of Valencia, Spain, using Thematic Mapper data. *International Journal of Remote Sensing*, 11: 301-311.

López, S.; González, F.; Llop, R. y Cuevas, J. M. (1991): «An evaluation of the utility of NOAA AVHRR images for monitoring forest fire risk in Spain», *International Journal of Remote Sensing*, 12: 1841-1851.

López Vizoso, J. M. (1987): «Cartografía automática de la ocupación del suelo en la comarca ferrolana», *Estudios Territoriales*, 25: 65-77.

— (1989): «La observación de la Tierra desde el espacio: el mapa de ocupación del suelo de la Comunidad Económica Europea», *Estudios Geográficos*, 50: 409-434.

Loveland, T. R.; Merchant, J. W.; Ohlen, D. O. y Brown, J. F. (1991): «Development of a Land-Cover Characteristics Database for the Conterminous U.S.», *Photogrammetric Engineering and Remote Sensing*, 57: 1453-1463.

Loveland, T. R.; Reed, B. C.; Brown, J. F.; Ohlen, D. O.; Zhu, J.; Yang, L. y Merchant, J. W. (2000): «Development of a global land cover characteristics database and IGBP DISCover from 1-km AVHRR data», *International Journal of Remote Sensing*, 21: 1303–1330.

Lulla, K. (1985): «Some observations on geobotanical remote sensing and mineral prospecting», *Canadian Journal of Remote Sensing*, 11: 17-38.

— (1993): «Space shuttle earth observations database for global urban applications», en *Cities of the World as Seen from Space* (editado por K. N. Au). Hong-Kong, Geocarto International: 15-19.

Lulla, K. P. y Dessinov, L. V. (eds.) (2000): *Dynamic Earth Environments. Remote Sensing Observations from Shuttle - Mir Missions*, Nueva York, John Wiley & Sons.

Lusch, R. (1989): «Spectral characteristics of land surfaces», en *Current Trends in Remote Sensing Education* (editado por M. D. Nellis, R. Lougeay y K. Lulla). Hong-Kong, Geocarto International Centre: 81-86.

Madsen, S. N. y Zebker, H. A. (1998): «Imaging Radar Interferòmetry», en *Principals and Applications of Imaging Radar* (editado por F. M. Henderson y A. J. Lewis). Nueva York, John Wiley & Sons, Inc.: 359-380.

Magaritz, M.; Kaufman, A.; Paul, M.; Boaretto, E. y Hollos, G. (1990): «A new method to determine regional evapotranspiration», *Water Resources Research*, 26: 1759-1762.

Maguire, D. J.; Goodchild, M. F. y Rhind, D. W. (eds.) (1991): *Geographical Information Systems. Principles and Applications*, Londres, Longman.

Malingreau, J. P.; Tucker, C. J. y Laporte, N. (1989): «AVHRR for monitoring global tropical deforestation», *International Journal of Remote Sensing*, 10: 855-867.

Markham, B. L. y Barker, J. L. (1987): «Radiometric properties of US processed Landsat MSS data», *Remote Sensing of Environment*, 22: 39-71.

Markham, G. L. y Townshend, J. R. G. (1981): «Land cover classification accuracy as a function of sensor spatial resolution», *15th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor: 1075-1090.

Marsh, S. E.; Switzer, P.; Kowalick, W. S. y Lyon, R. J. P. (1980): «Resolving the percentage of component terrains within single resolution elements», *Photogrammetric Engineering and Remote Sensing*, 46: 1079-1086.

Martin, L. R. G. (1989): «Accuracy assessment of Landsat-based visual change detection methods applied to the rural-urban fringe», *Photogrammetric Engineering and Remote Sensing*, 55: 209-215.

Martín, M. P. (1998): *Cartografía e inventario de incendios forestales en la Península Ibérica a partir de imágenes NOAA-AVHRR*, Departamento de Geografía, Alcalá de Henares, Universidad de Alcalá.

Martín, M. P. y Chuvieco, E. (1995): «Mapping and evaluation of burned land from multitemporal analysis of AVHRR NDVI images», *EARSeL Advances in Remote Sensing*, 4 (3): 7-13.

— (1998): «Cartografía de grandes incendios forestales en la Península Ibérica a partir de imágenes NOAA-AVHRR», *Serie Geográfica*, 7: 109-128.

Martin, M. P.; Chuvieco, E.; Oliva, P.; Rodriguez-Verdú, F.; Nieto, H. y Paredes, D. P. (2007): «Un ejemplo práctico de aplicación operativa de la teledetección a la gestión de riesgos naturales: cartografía y evaluación urgente de áreas quemadas en Galicia», *Cuadernos de investigación geográfica*, 33: 19-37.

Martín, M. P.; Ceccato, P.; Flasse, S. y Downey, I. (1999): «Fire detection and fire growth monitoring using satellite data», en *Remote Sensing of Large Wildfires in the European Mediterranean Basin* (editado por E. Chuvieco). Berlin, Springer-Verlag: 101-122.

Martín, M. P.; Gómez, I. y Chuvieco, E. (2005): «Performance of a burned-area index (BAIM) for mapping Mediterranean burned scars from MODIS data», en *Proceedings of the 5th International Workshop on Remote Sensing and GIS applications to Forest Fire Management: Fire Effects Assessment* (editado por J. Riva, F. Pérez-Cabello y E. Chuvieco). París, Universidad de Zaragoza, GOFC-GOLD, EARSeL: 193-198.

Martínez Vega, J. (1989): «Propuesta metodológica para la presentación cartográfica de los tipos dinámicos de ocupación y uso del suelo», *Estudios Geográficos*, 39: 235-258.

— (1996): «Una revisión sobre las imágenes espaciales como fuentes cartográficas», *Revista Española de Teledetección*, 6: 37-50.
— (1997): «Una revisión sobre las imágenes espaciales como recursos didácticos», *Revista Española de Teledetección*, 8: 15-26.
Martínez Vega, J.; Romero, R. y Echavarría, P. (2007): «Valoración paisajística y ecológica de la Comunidad de Madrid: su integración en un índice sintético de riesgo de incendios forestales», *Revista de Teledetección*, 28: 43-60
Martínez, J.; Vega, C. y Chuvieco, E. (2008): «Human-caused wildfire risk rating for prevention planning in Spain», *Journal of Environmental Management*: en prensa.
Marx, C. y Hildebrandt, G. (1978): «Qualitative and quantitative interpretation of Landsat MSS data to forest cover mapping in Germany», *International Symposium on Remote Sensing for Observation and Inventoty of Earth Resources and the Endangered Environment*, Freiburg: 1791-1804.
Maselli, F.; Conese, C.; De Filippis, T. y Norcini, S. (1995): «Estimation of forest parameters through fuzzy classification of TM data», *IEEE Transactions on Geoscience and Remote Sensing*, 33: 77-84.
Maselli, F.; Petkov, L.; Maracchi, G. y Conese, C. (1996): «Eco-climatic classification of Tuscany through NOAA-AVHRR data», *International Journal of Remote Sensing*, 17: 2369-2384.
Massonet, D.; Rossi, M.; Carmona, C.; Adragna, F.; Peltzer, G.; Feigl, K. y Rabaute, T. (1993): «The displacement field of the Landers Earthquake mapped by radar interferometry», *Nature*, 364: 138-142.
Massonet, D.; Briole, P. y Arnaud, A. (1995): «Deflation of Mount Etna monitored by spaceborne radar interferometry», *Nature*, 375: 567-570.
Mather, P. M. (1998): *Computer Processing of Remotely Sensed Images*, Chichester, John Wiley & Sons.
Mazer, A. S.; Martin, M.; Lee, M. y Solomon, J. E. (1988): «Image Processing software for Imaging Spectrometry Data Analysis», *Remote Sensing of Environment*, 24: 201-210.
McCloy, K. R. (1995): *Resource Management Information Systems. Process and Practice*, Londres, Taylor & Francis.
Mcdonald, R. A. (1995): «CORONA- success for space reconnaissance, a look into the Cold War, and a revolution for intelligence», *Photogrammetric Engineering and Remote Sensing*, 61: 689-720.
Mcgwire, K. C. (1996): «Cross-validated assessment of geometric accuracy», *Photogrammetric Engineering and Remote Sensing*, 62: 1179-1187.
Meliá, J.; Gandia, S. y Caselles, V. (1986): «Teledetección y signaturas espectrales», *Revista de la Real Academia de Ciencias Exactas, Físicas y Naturales*, 80: 177-185.
Meliá, J. y Sobrino, J. A. (1987): «A study on the utilization of SIR-A data for population estimation in the Eastern part of Spain», *Geocarto International*, 2: 33-38.
Mergerson, J. W. (1981): «Crop area estimates using ground gathered and Landsat data: A multitemporal approach», *15th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor: 1211-1218.
Meyer, P.; Itten, K. I.; Kellenbenberger, T.; Sandmeier, S. y Sandmeier, R. (1993): «Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment», *ISPRS Journal of Photogrammetry and Remote Sensing*, 48: 17-28.
Middelkoop, H. y Janssen, L. L. (1991): «Implementation of temporal relationships in knowledge based classification of satellite images», *Photogrammetric Engineering and Remote Sensing*, 57: 937-945.
Milton, E. J.; Rollin, E. M. y Emery, D. R. (1995): «Advances in field spectroscopy», en *Advances in Environmental Remote Sensing* (editado por F. M. Danson y S. E. Plummer). Chichester, John Wiley: 9-32.

Milton, N. M.; Collins, W.; Chang, S. H. y Schmidt, R. G. (1983): «Remote detection of metal anomalies on Pilot Mountain, Randolph County, North Carolina», *Economic Geology*, 78: 605-617.

Miller, L. D. y Williams, D. L. (1978): «Monitoring forest canopy alteration around the world with digital analysis of Landsat imagery», *International Symposium on Remote Sensing for Observation and Inventory of Earth Resources and the Endangered Environment*, Freiburg: 1721-1763.

Millington, A. C.; Wellens, J.; Settle, J. J. y Saull, R. J. (1994): «Explaining and monitoring land-cover dynamics in drylands using multi-temporal analysis of NOAA-AVHRR imagery», en *Environmental Remote Sensing from Regional to Global Scales* (editado por G. M. Foody y P. J. Curran). Chichester, John Wiley & Sons: 16-43.

Minnaert, M. (1941): «The reciprocity principle in lunar photometry», *The astrophysical journal*, 93: 403-410.

Mitas, L. y Mitasova, H. (1999): «Spatial Interpolation», en *Geographical Information Systems* (editado por P. A. Longley, M. F. Goodchild y y. D. W. Rhind). Nueva York, John Wiley & Sons, inc.

Moghaddam, M. y Saatchi, S. S. (1999): «Monitoring tree moisture using an estimation algorithm applied to SAR data from BOREAS», *IEEE Transactions on Geoscience and Remote Sensing*, 37: 901-916.

Molina, G. Z. y Chuvieco, E. (1997): «Detección del crecimiento urbano en la ciudad de Maracaibo (Venezuela) mediante análisis multitemporal de imágenes MSS y TM», en *Teledetección: usos y aplicaciones* (editado por J. L. Casanova y J. Sanz). Valladolid, Universidad de Valladolid: 361-368.

Molina, Z. (1998): *Análisis de calidad ambiental de vida para la ciudad de Maracay (Venezuela) usando la teledetección y los S.I.G.,* Departamento de Geografía, Alcalá de Henares, Universidad de Alcalá: 380.

Molina, Z. y Chuvieco, E. (1996): «Evaluación de índices texturales para discriminar morfología urbana: análisis de la ciudad de Maracay (Venezuela)», *Revista de Teledetección*: 49-57.

Molina, Z.; Barredo, J. I.; Díaz, M. A. y Chuvieco, E. (1999): «Propuesta para el análisis de la calidad ambiental de vida urbana en Latinoamérica mediante el empleo de las nuevas tecnologías», *Cooperación Internacional*, 2: 83-102.

Moller-Jensen, L. (1990): «Knowledge-based classification of an urban area using texture and context information in Landsat TM imagery», *Photogrammetric Engineering and Remote Sensing*, 56: 899-904.

Moore, G. K. y Waltz, F. A. (1983): «Objective procedures for lineament enhancement and extraction», *Photogrammetric Engineering and Remote Sensing*, 49: 641-647.

Morain, S. A. y Klankamsorn, B. (1978): «Forest mapping and inventory techniques through visual analysis of Landsat imagery: examples from Thailand», *12th International Symposium on Remote Sensing of Environment*, Ann Arbor: 417-426.

Morain, S. A. y Budge, A. M. (eds.) (1996): *Earth Observing Platforms and Sensors*, Manual of Remote Sensing, Bethesda, American Society of Photogrammetry and Remote Sensing.

Moran, M. S.; Clarke, T. R.; Inoue, Y. y Vidal, A. (1994): «Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index», *Remote Sensing of Environment*, 49: 246-263.

Moran, P. (1948): «The interpretation of statistical maps», *Journal of the Royal Statistical Society*, 108: 243-251.

Moreira, J. M. y Ojeda, J. (1992): *Andalucía, una visión inédita desde el espacio*, Sevilla, Agencia de Medio Ambiente, Junta de Andalucía.

Moreira, J. M. y Fernández-Palacios, A. (1995): *Usos y coberturas vegetales del suelo en An-*

dalucía. Seguimiento a través de imágenes de satélite, Sevilla, Consejería de Medio Ambiente, Junta de Andalucía.
Moreno, A. (Ed.) (2005): *Sistemas y análisis de la información geográfica. Manual de autoaprendizaje con ArcGIS*, Madrid, Editorial RA-MA.
Morisette, J. T.; Giglio, L.; Csiszar, I. y Justice, C. O. (2005): «Validation of the MODIS active fire product over Southern Africa with ASTER data. *International Journal of Remote Sensing*, 26: 4239-4264.
Mouat, D. A.; Mattin, G. G. y Lancaster, J. (1993): «Remote sensing techniques in the analysis of change detection. *Geocarto International*, 8: 39-50.
Mounsey, H. M. (1991): «Multisource, multinational environmental G.I.S.: leassons learnt from CORINE», en *Geographical Information Systems* (editado por D. Maguire, M. F. Goodchild y D. W. Rhind). Londres, Longman: 185-200.
Muchoki, C. H. K. (1988): «Remotely sensed relationships between wooded patch habitats and agricultural landscape type: a basis for ecological planning», en *Landscape ecology and management* (editado por M. R. Moss). Montreal, Polyscience Publications: 85-95.
Mulders, M. A. (1987): *Remote Sensing in Soil Science*, Amsterdam, Elsevier.
Muller, J. P. (ed.) (1988*a*): *Digital Image Processing in Remote Sensing*, Londres, Taylor & Francis.
— (1988*b*): «Computing issues in digital image processing in remote sensing», en *Digital Image Processing in Remote Sensing* (editado por J. P. Muller). Londres, Taylor & Francis: 1-20.
Munoz, J.; Felicisimo, A. M.; Cabezas, F.; Burgaz, A. R. y Martínez, I. (2004): «Wind as a Long-Distance Dispersal Vehicle in the Southern Hemisphere», *Science*, 304: 1144-1147.
Murphy, D. L. (1985): «Estimating neighborhood variability with a binary comparison matrix», *Photogrammetric Engineering and Remote Sensing*, 51: 667-674.
Murphy, R. E. (2006): «The NPOESS Preparatory Project», en *Earth Science Satellite Remote Sensing. Vol. 1: Science and Instruments* (editado por Q. J. J., G. Wei, M. Kafatos, R. E. Murphy y V. V. Salomonson). Beijing, Tsinghua University Press and Springer Verlag: 183-198.
Murtha, P. A. (1978): «Remote sensing and vegetation damage: a theory for detection and assessment», *Photogrammetric Engineering and Remote Sensing*, 44: 1147-1158.
Myneni, R. B. y Asrar, G. (1994): «Atmospheric effects and spectral vegetation indices», *Remote Sensing of Environment*, 47: 390-402.
Myneni, R. B.; Hall, F. G.; Sellers, P. J. y Marshak, A. L. (1995): «The interpretation of spectral vegetation indexes», *IEEE Transactions on Geoscience and Remote Sensing*, 33: 481-486.
Nasa (1976): *Mission to Earth. Landsat Views of the World*, Greenbelt, Goodard Space Flight Center, SP 360.
— (1977): *Skylab Explores the Earth*, Washington, D. C., NASA, SP 380.
— (2000): *Modis. Moderate Resolution Imaging Spectroradiometer*, National Aeronautics and Space Administration. USA,
National Audubon Society (1995): *Earth from Space*, Nueva York, Alfred A. Knopf.
National Geographic (1999): *Satelllite Atlas of the World*, Washington, D. C., National Geographic Society.
National Research Council (2007): *Surface Temperature Reconstructions for the Last 2,000 Years*, Washington, D. C., National Academy of Sciences (http://www.nap.edu/catalog/11676.html).
Ne'eman, G.; Fotheringham, C. J. y Keely, J. E. (1999): «Patch to landscape patterns in post fire recruitment of a serotinous conifer», *Plant Ecology*, 145: 235-242.
Nelson, B. W. (1994): «Natural forest disturbance and change in the Brazilian Amazon», *Remote Sensing Reviews*, 10: 105-125.

Nelson, R. y Grebowsky, G. (1982): «Evaluation of temporal registration of Landsat scenes», *International Journal of Remote Sensing*, 3: 45-50.

Nemani, R. R.; Pierce, L.; Running, S. W. y Edward, S. (1993): «Developing satellite-derived estimates of surface moisture status», *Journal of Applied Meteorology*, 32: 548-557.

Nikolaus, S. (1988): «Visual and digital classification of Landsat TM data for soil, physiography and land use mapping in Axios alluvial plain, Thessaloniki, Greece», *Geocarto International*, 4: 55-66.

Novak, K. (1992): «Rectification of digital imagery», *Photogrammetric Engineering and Remote Sensing*, 58: 339-344.

Núñez De Las Cuevas, R. (1976): *Thematic Mapping, Land Use, Geological Structure and Water Resources in Central Spain*, Madrid, NASA Project - Instituto Geográfico Nacional.

Núñez De Las Cuevas, R.; Chuvieco, E.; Sancho, J.; Palou, F. y Casas, J. M. (1983): «Mapa de usos del suelo de la región central. Estudio piloto sobre la aplicación del tratamiento digital de imágenes Landsat a la confección de mapas de usos del suelo», *Geographica*, 25: 61-78.

O'Connell, K. M. y Hilgenberg, G. (2001): «U.S. Remote Sensing programs and policies», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 139-163.

O'Connell, K. M. y Lachman, B. E. (2001): «From space imagery to information: commercial remote sensing market factors and trends», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 53-78.

O'Neill, R. V.; Krummel, J. R.; Gardner, R. H.; Sugihara, G. y Jackson, B. (1988): «Indices of landscape pattern», *Landscape Ecology*, 1: 153-162.

O.T.A. (1994): *Remotely Sensed Data: Technology, Management and Markets*, Washington, D. C., U. S. Government Printing Office - U. S. Congress, Office of Technology Assessment, OTA-ISS-604.

— (1984): *Remote Sensing and the Private Sector: Issues for Discussion. A Technical Memorandum*, Washington, D. C., U. S. Congress, Office of Technology Assessment, OTA-TM-ISC-20.

Observatorio De La Sostenibilidad (2006): *Cambios de ocupación del suelo en España: implicaciones para la sostenibilidad. Principales resultados a nivel nacional y por Comunidades Autónomas*, Madrid, Ministerio de Medio Ambiente.

Olorunfemi, J. F. (1987): «Identification and measurement of the areal extent settlements from Landsat», *International Journal of Remote Sensing*, 8: 1839-1843.

Ortí, F.; García, A. y Martín, M. A. (1979): «Geometric correction of MSS Landsat images using a ground control point library», en *Remote Sensing and National Mapping* (editado por J. Allan y R. Harris). Londres, Remote Sensing Society: 17-26.

Ouaidrari, H. y Vermote, E. F. (1999): «Operational Atmospheric Correction of Landsat TM Data», *Remote Sensing of Environment*, 70: 4-15.

Palà, V. y Pons, X. (1995): «Incorporation of relief in polynomial-based geometric corrections», *Photogrammetric Engineering and Remote Sensing*, 61: 935-944.

Palacios-Orueta, A. y Ustin, S. L. (1996): «Multivariate statistical classification of soil spectra», *Remote Sensing of Environment*, 57: 108-118.

Palacios-Orueta, A. y Ustin, S. L. (1998): «Remote sensing of soil properties in the Santa Monica Mountains I. Spectral Analysis», *Remote Sensing of Environment*, 65: 170-183.

Palacios-Orueta, A.; Pinzon, J. E.; Ustin, S. L. y Roberts, D. A. (1999): «Remote sensing of soil properties in the Santa Monica Mountains II. Hierarchical Foreground and Background Analysis», *Remote Sensing of Environment*, 68: 138-151.

Palacios-Orueta, A.; Chuvieco, E.; Parra, A. y Carmona-Moreno, C. (2005): «Biomass burning emissions: A review of models using remote-sensing data», *Environmental Monitoring and Assessment*, 104: 189-209.

Paloscia, S. (1994): «Microwave emission from vegetation», en *Passive Microwave Remote Sensing of Land-Atmosphere Interactions* (editado por B. J. Choudhury, Y. H. Kerr, E. G. Njoku y P. Pampaloni). Utrecht, VSP BV: 357-374.

Paloscia, S. y Pampoloni, P. (1984): «Microwave remote sensing of plant water stress», *Remote Sensing of Environment*, 16: 249-255.

Paltridge, G. W. y Barber, J. (1988): «Monitoring grassland dryness and fire potential in Australia with NOAA/AVHRR data», *Remote Sensing of Environment*, 25: 381-394.

Parkinson, C. L.; Ward, A. y King, M. D. (eds.) (2006): *Earth Science Reference Handbook. A Guide to NASA's Earth Science Program and Earth Observing Satellite Missions*, Washington, D. C., National Aeronautics and Space Administration.

Pastor, J. y Broshart, M. (1990): «The spatial pattern of a Northern conifer-hardwood landscape», *Landscape Ecology*, 4: 55-68.

Pellemans, A. H.; Jordans, R. W. y Allewijn, R. (1993): «Merging multispectral and pancromatic SPOT images with respect to the radiometric properties of the sensor», *Photogrammetric Engineering and Remote Sensing*, 59: 81-87.

Pereira, J. M. C. (1999): «A Comparative Evaluation of NOAA/AVHRR Vegetation Indexes for Burned Surface Detection and Mapping», *IEEE Transactions on Geoscience and Remote Sensing*, 37: 217-226.

Pereira, J. M. C.; Sa, A. C. L.; Sousa, A. M. O.; Martín, M. P. y Chuvieco, E. (1999): «Regional-scale burnt area mapping in Southern Europe using NOAA-AVHRR 1 km data», en *Remote Sensing of Large Wildfires in the European Mediterranean Basin* (editado por E. Chuvieco). Berlín, Springer-Verlag: 139-155.

Perry, C. R. y Lautenschlager, L. F. (1984): «Functional equivalence of spectral vegetation indices», *Remote Sensing of Environment*, 14: 169-182.

Peters, A.; Rundquist, D. C. y Wilhite, P. A. (1991): «Satellite detection of the geographic core of the 1988 Nebraska drought», *Agricultural and Forest Meteorology*, 57: 35-47.

Pickup, G. y Foran, B. D. (1987): «The use of spectral and spatial variability to monitor cover change on inert landscapes», *Remote Sensing of Environment*, 23: 351-363.

Pilon, P.; Howarth, P. J.; Bullock, R. A. y Adeniyi, P. O. (1988): «An enhanced classification approach to change detection in semi-arid environments», *Photogrammetric Engineering and Remote Sensing*, 54: 1709-1716.

Pinilla, C. (1995): *Elementos de Teledetección Espacial*, Madrid, RA-MA.

Pinilla, C.; Alcalá, A. y Ariza, F. J. (1997): «Filtrado de imágenes en el dominio de la frecuencia», *Revista Española de Teledetección*, 8: 47-52.

Pinty, B. y Verstraete, M. M. (1992): «GEMI: a non-linear index to monitor global vegetation from satellites», *Vegetatio*, 101: 15-20.

Pinzón, J. E.; Ustin, S. L.; Castañeda, C. M. y Smith, M. O. (1998): «Investigation of Leaf biochemistry by Hierarchical Foreground / Background Analysis», *IEEE Transactions on Geoscience and Remote Sensing*, 36: 1913-1927.

Podwysocki, M. H.; Power, M. S. y Jones, O. D. (1985): «Preliminary evaluation of the Landsat-4 Thematic Mapper data for mineral exploration», en *The Earth's Surface Studied from Space, Advances in Space Research* (editado por S. G. Ungar). Oxford, Pergamon Press: 13-20.

Pons, X. y Solé-Sugrañes, L. (1994): «A Simple Radiometric Correction Model to Improve Automatic Mapping of Vegetation from Multispectral Satellite Data», *Remote Sensing of Environment*, 48: 191-204.

Pontius, J.; Robert G.; Shusas, E. y Mceachern, M. (2004): «Detecting important categorical

land changes while accounting for persistence», *Agriculture, Ecosystems & Environment*, 101: 251-268.

Potter, C. S. y Brooks, V. (2000): «Global analysis of empirical relations between annual climate and seasonality of NDVI», *International Journal of Remote Sensing*, 19: 2921-2948.

Prados, M. J. (1995): «La utilización de imágenes Landsat-5 TM para la estimación y seguimiento de áreas de monocultivo arrocero y su vinculación a espacios naturales», *Revista de Teledetección*, 5: 44-48.

Price, J. C. (1987): «Calibration of satellite radiometers and the comparison of vegetation indices», *Remote Sensing of Environment*, 21: 15-27.

— (2003): «Comparing MODIS and ETM+ data for regional and global land clasification», *Remote Sensing of Environment*, 86: 491-499.

Privette, J. L.; Fowler, C.; Wick, G. A.; Baldwin, D. y Emery, W. J. (1995): «Effects of orbital drift on Advanced Very High Resolution Radiometer products: Normalized Difference Vegetation Index and Sea Surface Temperature», *Remote Sensing of Environment*, 53: 164-171.

Pu, R. y Gong, P. (2004): «Determination of Burnt Scars Using Logistic Regression and Neural Network Techniques from a Single Post-Fire Landsat-7 ETM+ Image», *Photogrammetric Engineering and Remote Sensing*, 70: 841-850.

Pu, R. L.; Li, Z. Q.; Gong, P.; Csiszar, I.; Fraser, R.; Hao, W.-M.; Kondragunta, S. y Weng, F. (2007): «Development and analysis of a 12-year daily 1-km forest fire North America from NOAA/AVHRR data», *Remote Sensing of Environment*, 108: 198-208.

Quarmby, N. A.; Townshend, J. R. G.; Settle, J. J.; White, K. H.; Milnes, M.; Hindle, T. L. y Silleos, N. (1992): «Linear mixture modelling applied to AVHRR data for crop area estimation», *International Journal of Remote Sensing*, 13: 415-425.

Quattrochi, D. A. y Goodchild, M. F. (eds.) (1997): *Scale in Remote Sensing and GIS*, Boca Raton, CRC Press, Inc.

Quegan, S. (1995): «Recent advances in understanding SAR imagery», en *Advances in Environment Remote Sensing* (editado por F. M. Danson y S. E. Plummer). Chichester, John Wiley & Sons: 89-104.

Rabus, B.; Eineder, M.; Roth, A. y Bamler, R. (2003): «The shuttle radar topography mission–a new class of digital elevation models acquired by spaceborne radar. *ISPRS Journal of Photogrammetry and Remote Sensing*, 57: 241-262.

Ranson, K. J.; Sun, G.; Kharuk, V. I. y Kovacs, K. (2001): «Characterization of forests in Western Sayani Mountains, Siberia from SIR-C SAR data», *Remote Sensing of Environment*, 75: 188-200.

Rebollo, M. y Orti, F. (1980): *Pattern Recognition Techniques: Remote Sensing Applications at Centro de Investigación UAM-IBM*, Madrid, Centro de Investigación UAM-IBM.

Rees, G. (1999): *The Remote Sensing Data Book*, Cambridge, Cambridge University Press.

Reinhardt, E. D. y Ringleb, R. V. (1990): «Analysis of changes in patterns of a forested landscape following wildfire using Landsat data and landscape ecology methodology», *Resource Technollogy 90*, Washington D. C., American Society of Photogrammetry and Remote Sensing: 83-93.

Rencz, A. y Ryerson, R. A. (eds.) (1999): *Remote Sensing for the Earth Sciences*, Manual of Remote Sensing, Nueva York, John Wiley & Sons.

Renz, A. N. (1985): «Multitemporal analysis of Landsat imagery for monitoring forest cutovers in Nova Scotia», *Canadian Journal of Remote Sensing*, 11: 189-194.

Rhind, D. y Clark, P. (1988): «Cartographic data inputs to global databases», en *Building Databases for Global Science* (editado por H. Mounsey). Londres, Taylor & Francis: 79-104.

Riaño, D.; Vaughan, P. y Chuvieco, E. (2000): «Bases para estimar el contenido de humedad en plantas mediterráneas a partir de la teledetección», *Mediterránea. Serie de estudios biológicos. Época II*: 27-34.

Riaño, D.; Salas, J. y Chuvieco, E. (2001): «Cartografía de modelos de combustible con teledetección: aportaciones a un desarrollo ambiental sostenible», *Estudios Geográficos*, 62: 309-333.

Riaño, D.; Chuvieco, E.; Salas, J.; Palacios-Orueta, A. y Bastarrica, A. (2002*a*): «Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems», *Canadian Journal of Forest Research*, 32: 1301-1315.

Riaño, D.; Chuvieco, E.; Ustin, S. L.; Zomer, R.; Dennison, P.; Roberts, D. y Salas, J. (2002*b*): «Assessment of vegetation regeneration after fire through multitemporal analysis of AVIRIS images in the Santa Monica Mountains», *Remote Sensing of Environment*, 79: 60-71.

Riaño, D.; Chuvieco, E.; Salas, F. J. y Aguado, I. (2003): «Assessment of Different Topographic Corrections in Landsat-TM Data for Mapping Vegetation Types», *IEEE Transactions on Geoscience and Remote Sensing*, 41: 1056-1061.

Riaño, D.; Chuvieco, E.; Condés, S.; González-Matesanz, J. y Ustin, S. L. (2004*a*): «Generation of crown bulk density for Pinus sylvestris L. from lidar», *Remote Sensing of Environment*, 92: 345–352.

Riaño, D.; Valladares, F.; Condés, S. y Chuvieco, E. (2004*b*): «Estimation of leaf area index and covered ground from airborne laser scanner (Lidar) in two contrasting forests», *Agricultural and Forest Meteorology*, 124: 269–275.

Riaño, D.; Ustin, S. L.; Usero, L. y Patricio, M. A. (2005*a*): «Estimation of fuel moisture content using neural networks», *Artificial Intelligence and Knowledge Engineering Applications: A Bioinspired Approach, Pt 2, Proceedings*, 3562: 489-498.

Riaño, D.; Vaughan, P.; Chuvieco, E.; Zarco-Tejada, P. y Ustin, S. L. (2005*b*): «Estimation of Fuel Moisture Content by Inversion of Radiative Transfer Models to Simulate Equivalent Water Thickness and Dry Matter Content: Analysis at Leaf and Canopy Level», *IEEE Transactions on Geoscience and Remote Sensing*, 43: 819-826.

Riaño, D.; Chuvieco, E.; Ustin, S. L.; Salas, J.; Rodríguez-Pérez, J. R.; Ribeiro, L. M.; Viegas, D. X.; Moreno, J. M. y Fernández, H. (2007*a*): «Estimation of shrub height for fuel type mapping combining airborne LIDAR and simultaneous color infrared ortho image», *International Journal of Wildland Fire*, 16: 341-348.

Riaño, D.; Ruiz, J. A. M.; Isidoro, D.; Ustin, S. L. y Riaño, D. (2007*b*): «Global spatial patterns and temporal trends of burned area between 1981 and 2000 using NOAA-NASA Pathfinder», *Global Change Biology*, 13: 40-50, doi: 10.1111/j.1365-2486.2006.01268.

Ricotta, C.; Avena, G. C.; Olsen, E. R.; Ramsey, R. D. y Winn, D. S. (1998): «Monitoring the landscape stability of the Mediterranean vegetation in relation to fire with a fractal algorithm», *International Journal of Remote Sensing*, 19: 871-881.

Ricotta, C. y Retzlaff, R. (2000): «Self-similar spatial clustering of wildland fires: the example of a large wildfire in Spain», *International Journal of Remote Sensing*, 21: 2113-2118.

Richards, J. A. (1993): *Remote Sensing Digital Image Analysis. An Introduction*, Berlín, Springer-Verlag.

Richards, J. A. y Xia, X. (1999): *Remote Sensing Digital Image Analysis. An Introduction*, Berlín, Springer-Verlag.

Richter, R. (1996): «Atmospheric correction of satellite data wih haze removal including a haze/clear transition region», *Computers and Geosciences*, 22: 675-681.

— (1997): «Correction of atmospheric and topographic effects for high spatial resolution satellite imagery», *International Journal of Remote Sensing*, 18: 1099-1111.

Riitters, K. H.; O'Neill, R. V.; Hunsaker, C. T.; Wickham, J. D.; Yankee, D. H. y Timmins, S. P. (1995): «A factor analysis of landscape pattern and structure metrics», *Landscape Ecology*, 10: 23-39.

Ripple, W. J.; Bradshaw, G. A. y Spies, T. A. (1991): «Measuring forest landscape patterns in the cascade range of Oregon», *Biological Conservation*, 57: 73-88.

Roberts, D.; Smith, G. M. y Adams, M. L. (1993): «Green Vegetation, Non photosinthetic vegetation and soils in AVIRIS data», *Remote Sensing of Environment*, 44: 255-269.

Roberts, D.; Gardner, M.; Regelbrugge, J.; Pedreros, D. y Ustin, S. (1997): «Mapping the distribution of Wildfire fuels using AVIRIS in the Santa Monica Mountains», *Summaries of the Seventh JPL Airbone Earth Science Workshop*, Pasadena, California, Jet Propulsion Laboratory: 345-352.

Roberts, D. A.; Gardner, M.; Church, R.; Ustin, S.; Scheer, G. y Green, R. O. (1998): «Mapping chaparral in the Santa Monica Mountains using multiple endmembers spectral mixture models», *Remote Sensing of Environment*, 65: 267-279.

— (2003): «Evaluation of the Potential of Hyperion for Fire Danger Assessment by Comparison to the Airborne Visible/Infrared Imaging Spectrometer», *IEEE Transactions on Geoscience and Remote Sensing*, 4: 1297-1310.

Robin, M. (1998): *La Télédétection*, París, Nathan.

Robinove, C. (1981): «The logic of multispectral classification and mapping the land», *Remote Sensing of Environment*, 11: 231-244.

Robinson, G. D.; Gross, H. N. y Schott, J. R. (2000): «Evaluation of Two Applications of Spectral Mixing Models to Image Fusion», *Remote Sensing of Environment*, 71: 272-281.

Robinson, I. S. (1985): *Satellite Oceanography. An Introduction for Oceanographers and Remote Sensing Scientist*, Chichester, John Wiley.

Rock, B. N.; Moshizaki, T. y Miller, J. R. (1988): «Comparison of in situ and airborne spectral measurements of the blue shift associated with forest decline», *Remote Sensing of Environment*, 24: 109-127.

Rosborough, G. W.; Baldwin, D. y Emery, W. J. (1994): «Precise AVHRR image navigation», *IEEE Transactions on Geoscience and Remote Sensing*, 32: 644-657.

Rosenfeld, G. H. (1982): «Sample design for estimating change in land use and land cover», *Photogrammetric Engineering and Remote Sensing*, 48: 793-801.

Rosenfeld, G. H.; Fitzpatrick-Lins, K. y Ling, H. S. (1982): «Sampling for thematic map accuracy testing», *Photogrammetric Engineering and Remote Sensing*, 48: 131-137.

Rouse, J. W.; Haas, R. W.; Schell, J. A.; Deering, D. H. y Harlan, J. C. (1974): *Monitoring the vernal advancement and retrogradation (Greenwave effect) of natural vegetation*, Greenbelt, MD. USA, NASA/GSFC,

Roy, D. (2000): «The impact of misregistration upon composited wide field of view satellite data and implications for change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 38: 2017-2032.

Roy, D.; Frost, P.; Justice, C.; Landmann, T.; Roux, J.; Gumbo, K.; Makungwa, S.; Dunham, K.; Du Toit, R.; Mhwandagara, K.; Zacarias, A.; Tacheba, B.; Dube, O.; Pereira, J.; Mushove, P.; Morisette, J.; Santhana, S. y Davies, D. (2005): «The Southern Africa Fire Network (SAFNet) regional burned area product validation protocol», *International Journal of Remote Sensing*, 26: 4265-4292.

Roy, P. S. y Tomar, S. (2000): «Biodiversity characterization at landscape level using geospatial modelling technique», *Biological Conservation*, 95: 95-109.

Ruiz-Verdú, A.; Domínguez, J. A. y Peña, R. (2001): «Teledetección aeroportada hiperespectral del embalse de Ribarroja», en *Teledetección. Medioambiente y Cambio Global* (editado por J. I. Rosell y J. A. Martínez-Casasnovas). Lleida, Universitat de Lleida y Editorial Milenio: 318-321.

Ruiz, G. (1992): *Imagen de Venezuela. Una visión espacial*, Caracas, Petroleos de Venezuela.

Ruiz, L. A. (1994): *Introducción al tratamiento digital de imágenes*, Valencia, Universidad Politécnica, Servicio de Publicaciones.

Rumelhart, D. E.; Hinton, G. E. y Williamns, R. J. (1986): «Learning representations by back-propagating errors», *Nature*, 323: 533-535.

Sadar, S. A.; Linden, D. S. y Mcguire, M. (1982): «Fuels mapping from Landsat imagery and digital terrain data for fire supression decisions», *ACSM-ASP Congress*, Fort Lauderdale: 345-351.

Sader, S. A. y Winne, J. C. (1992): «RGB-NDVI colour composites for visualizing forest change dynamics», *International Journal of Remote Sensing*, 13: 3055-3067.

Sagdejew, R. S. (1982): *Atlas Zur Interpretation Aerokosmischer Multispektralaufnahmen*, Berlín, Akademie Verlag y Moscú Verlag Nauka.

Salas, F. J. y Chuvieco, E. (1995): «Aplicación de imágenes Landsat-TM a la cartografía de modelos combustibles», *Revista de Teledetección*, 5: 18-28.

Saleska, S. R.; Didan, K.; Huete, A. R. y Da Rocha, H. R. (2007): «Amazon Forests Green-Up During 2005 Drought», *Science*, 318: 612, DOI: 10.1126/science.1146663.

Salisbury, J. W. y D'aria, D. M. (1992): «Emissivity of terrestrial materials in the 8-14 μm atmospheric window», *Remote Sensing of Environment*, 42: 83-106.

— (1994): «Emissivity of terrestrial materials in the 3-5 μm. atmospheric window», *Remote Sensing of Environment*, 47: 345-361.

Sample, V. A. (ed.) (1994): *Remote Sensing and GIS in Ecosystem management*, Washington, D. C., The Island Press.

Sánchez, M. I. (1992): *Métodos para el estudio de la evaporación y evapotranspiración*, Logroño, Cuadernos Técnicos de la Sociedad Española de Geomorfología. Geoforma Ediciones,

Sánchez, M. I. y Chuvieco, E. (2000): «Estimación de evapotranspiración del cultivo de referencia, ETo, a partir de imágenes NOAA-AVHRR», *Revista Española de Teledetección*, 14: 11-21.

Sancho, J. (1992): «Imagen y Paisaje», en *Atlas Nacional de España* (editado por I.G.N.). Madrid, Instituto Geográfico Nacional: Sección I. Grupo 3c.

Sancho, J. y Chuvieco, E. (1986): *Castellón desde el Espacio*, Castellón, Caja de Ahorros de Castellón de la Plana.

— (eds.) (1992): *Iberoamérica desde el Espacio*, Madrid, Lunwerg - Sociedad Estatal Quinto Centenario - CNIG - Universidad de Alcalá.

Sandholt, I.; Rasmussen, K. y Andersen, J. (2002): «A simple interpretation of the surface temperature / vegetation index space for assessment of surface moisture status», *Remote Sensing of Environment*, 79: 213-224.

Sandmeier, S. R. y Deering, D. W. (1999): «Structure Analysis and Classification of Boreal Forests Using Airborne Hyperspectral BRDF Data from ASAS», *Remote Sensing of Environment*, 69: 281-295.

Sandmeier, S. R. y Itten, K. I. (1999): «A Field Goniometer System (FIGOS) for Acquisition of Hyperspectral BRDF data», *IEEE Transactions on Geoscience and Remote Sensing*, 37: 978-986.

Santurette, P. y Georgiev, C. G. (2005): *Weather Analysis and Forecasting: Applying Satellite Water Vapor Imagery and Potential Vorticity Analysis*, Bulington, MA, Academic Press.

Saunders, R. W. y Kriebel, K. T. (1988): «An improved method for detecting clear sky and cloudy radiances from AVHRR data», *International Journal of Remote Sensing*, 9: 123-150.

Saura, S. (2002): *Influencia de la escala en la configuración del paisaje: estudio mediante un nuevo método de simulación espacial, imágenes de satélite y cartografías temáticas*, E.T.S.I. Montes, Madrid, Universidad Politécnica de Madrid: 194.

Saura, S. y Martínez Millán, F. J. (2001): «Sensitivity of landscape pattern metrics to map spatial extent», *Photogrammetric Engineering and Remote Sensing*, 67: 1027-1036.

Saura, S. y San Miguel, J. (2001): «Cartografía de zonas forestales en España mediante imágenes IRS-WIFS y árboles de clasificación», en *Teledetección. Medioambiente y Cambio Global* (editado por J. I. Rosell y J. A. Martínez-Casasnovas). Lleida, Universitat de Lleida y Editorial Milenio: 151-154.

Scott, J. C. (ed.) (1997): *Report on Earth Observation, Hazard Analysis and Communications Technology for Early Warning*, United Nations International Decade for Natural Disaster Reduction IDNDR Early Warning Programme, Génova, IDNDR Secretariat.

Schaaf, C. B.; Gao, F.; Strahler, A. H.; Lucht, W.; Li, X.; Tsang, T.; Strugnell, N. C.; Zhang, X.; Jin, Y.; Muller, J.-P.; Lewis, P.; Barnsley, M.; Hobson, P.; Disney, M.; Roberts, G.; Dunderdale, M.; Doll, C.; D'Entremont, R. P.; Hug, B.; Liang, S.; Privette, J. L. y Roy, D. (2002): «First operational BRDF, albedo nadir reflectance products from MODIS», *Remote Sensing of Environment*, 1-2: 135–148.

Schiewe, J.; Tufte, L. y Ehlers, M. (2001): «Potential and problems of multi-scale segmentation methods in remote sensing», *GIS*, 06: 34-39.

Schneider, S. (1980): «Interpretation of satellite imagery for determination of land use data», *International Journal of Remote Sensing*, 1: 85-90.

Schowengerdt, R. A. (1983): *Techniques for Image Processing and Classification in Remote Sensing*, Nueva York, Academic Press.

— (1997): *Remote Sensing. Models and methods for image processing*, San Diego, California, Academic Press.

Schriever, J. R. y Congalton, R. G. (1995): «Evaluating seasonal variability as an aid to cover-type mapping from Landsat Thematic Mapper data in the Northeast», *Photogrammetric Engineering and Remote Sensing*, 61: 321-327.

Schroeder, M. (1986): «Spacelab Metric Camera Experiments», en *Satellite Remote Sensing for Resources Development* (editado por K. H. Szekielda). Londres, Graham & Trotman Ltd: 81-92.

Sellers, P. J. (1987): «Canopy reflectance, photosynthesis and transpiration: II. The role of biophysics in the linearity of their interdependence», *Remote Sensing of Environment*, 21: 143-183.

Sellers, P. J. (1989): «Vegetation-Canopy Spectral reflectance and Biophysical Processes», en *Theory and Applications of Optical Remote Sensing* (editado por G. Asrar). Nueva York, Wiley: 297-335.

Settle, J. J. y Drake, N. A. (1993): «Linear mixing and the estimation of ground cover proportions», *International Journal of Remote Sensing*, 14: 1159-1177.

Shaw, G. y Wheeler, D. (1985): *Statistical Techniques in Geographical Analysis*, Chichester, Wiley.

Sheffield, C. (1981): *Earth Watch. A Survey of the World from Space*, Londres, Sidgwick & Jackson Ltd.

— (1983): *Man on Earth. The Marks of Man, A Survey from Space*, Londres, Sidgwick & Jackson Ltd.

— (1985): «Selecting band combinations from multispectral data», *Photogrammetric Engineering and Remote Sensing*, 51: 681-687.

Shepherd, A.; Wingham, D.; Payne, T. y Skvarca, P. (2003): «Larsen Ice Shelf Has Progressively Thinned», *Science*, 302: 856-859.

Shepherd, J. D. y Dymond, J. R. (2000): «BRDF Correction of Vegetation in AVHRR Imagery», *Remote Sensing of Environment*, 74: 397-408.

Shimabukuro, Y. E. y Smith, J. A. (1991): «The Least-Squares Mixing Models to Generate

Fraction Images Derived from Remote Sensing Multispectral Data», *IEEE Transactions on Geosciences and Remote Sensing*, 29: 16-20.

Shimabukuro, Y. E.; Holben, B. N. y Tucker, C. J. (1994): «Fraction images derived from NOAA-AVHRR data for studying the deforestation in the Brazilian Amazon», *International Journal of Remote Sensing*, 15: 517-520.

Short, N. M. (1982): *The Landsat Tutorial Workbook: Basics of Satellite Remote Sensing*, Washington, D. C., NASA Scientific and Technical Information Branch.

—(2006): «The Remote Sensing Tutorial (An Online Handbook). Applied Information Sciences Branch», NASA's Goddard Space Flight Center (http://rst.gsfc.nasa.gov).

Short, N. M. y Stuart, L. M. (1982): *The Heat Capacity Mapping Mission (HCMM) Anthology*, Washington D. C., NASA Scientific and Technical Information Branch.

Short, N. M. y Blair, R. W. (eds.) (1986): *Geomorphology from Space*, Washington, D. C., NASA, Scientific and Technical Information Branch.

Siljeström, P. y Moreno, A. (1995): «Monitoring burnt areas by principal components analysis of multi-temporal TM data», *International Journal of Remote Sensing*, 16: 1577-1587.

Silva, J. M. N.; Cadima, J. F. C. L.; Pereira, J. M. C. y Gregoire, J. M. (2004): «Assessing the feasibility of a global model for multi-temporal burned area mapping using SPOT-VEGETATION data», *International Journal of Remote Sensing*, 25: 4889-4913.

Simpson, J. J. y Gobat, J. I. (1996): «Improved Cloud Detection for Daytime AVHRR Scenes over Land», *Remote Sensing of Environment*, 55: 21-49.

Singh, A. (1986): «Change detection in the tropical forest environment of Northeastern India using Landsat», en *Remote Sensing and Tropical Land Management* (editado por M. J. Eden y J. T. Parry). Chichester, John Wiley: 237-254.

Skidmore, A. K. (1989): «An expert system classifies eucalypt forest types using Thematic Mapper data and digital terrain model», *Photogrammetric Engineering and Remote Sensing*, 55: 1149-1464.

Skole, D. y Tucker, C. (1993): «Tropical deforestation and habitat fragmentation in the Amazon. Satellite data from 1978 to 1988», *Science*, 260: 1905-1910.

Slater, P. N. (1980): *Remote Sensing, Optics and Optical Systems*, Reading, MA, Addison-Wesley Pub. Co.

Slavik, B. (1974): *Methods for Studying Plant Water Relations*, Praga, Checoslovaquia Academy of Sciences - Springer Verlag.

Smith, J. L. y Kovalick, B. (1985): «A comparison of the effects of resampling before and after classification on the accuracy of a Landsat derived cover type map», *Advances Techiques for Monitoring Global Environmental Data*, Londres: 391-399.

Smith, M. O.; Ustin, S. L.; Adams, J. B. y Gillespie, A. R. (1990*a*): «Vegetation in deserts: I. A regional measure of abundance from multispectral images», *Remote Sensing of Environment*, 31: 1-26.

Smith, M. O.; Ustin, S. L.; Adams, J. B. y Gillespie, A. R. (1990*b*): «Vegetation in deserts: II. Environmental influences on regional vegetation», *Remote Sensing of Environment*, 31: 27-52.

Smith, R. M. (1984): *Images of the World. An Atlas of Satellite Imagery and Maps*, Essex, Collins-Longman.

Smits, P. y Annoni, A. (1999): «Updating land-cover maps by using texture information from very high-resolution space-borne imagery», *IEEE Transactions on Geoscience and Remote Sensing*, 37: 1244-1254.

— (2000): «Toward specification-driven change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 38: 1484-1488.

Snedecor, G. W. y Cochran, W. G. (1980): *Statistical Methods*, Ames, The Iowa University Press.

Sobrino, J. A. (ed.) (2000): *Teledetección*, Valencia, Servicio de Publicaciones, Universidad de Valencia.

Sobrino, J. A. (2008): «Water-vapour retrieval from Meteosat 8/SEVIRI observations», *International Journal of Remote Sensing*, 29: 741-754.

Sobrino, J. A.; Jiménez-Muñoz, J. C. y Paolini, L. (2004): «Land surface temperature retrieval from LANDSAT TM 5», *Remote Sensing of Environment*, 90: 434-440.

Souza, C. M.; Roberts, D. A. y Cochrane, M. A. (2005): «Combining spectral and spatial information to map canopy damage from selective logging and forest fires», *Remote Sensing of Environment*, 98: 329-343.

Srinivasan, A. y Richards, J. A. (1990): «Knowledge-based techniques for multi-source classification», *International Journal of Remote Sensing*, 11: 505-525.

Star, J. L. y Estes, J. E. (1990): *Geographic Information Systems*, Englewood Cliffs, Prentice Hall.

Star, J. L.; Estes, J. E. y Davis, F. (1991): «Improved integration of remote sensing and Geographic Information Systems: a background to NCGIA initiative 12», *Photogrammetric Engineering and Remote Sensing*, 57: 643-645.

Stehman, S. V. (1992): «Comparison of systematic and random sampling for estimating the accuracy of maps generated from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 58: 1343-1350.

— (1999*a*): «Comparing thematic maps based on map value», *International Journal of Remote Sensing*, 20: 2347-2366.

— (1999*b*): «Basic probability sampling designs for thematic map accuracy assessment», *International Journal of Remote Sensing*, 20: 2423-2441.

Steven, M. D. y Jaggard, K. W. (1995): «Advances in crop monitoring by remote sensing», en *Advances in Environmental Remote Sensing* (editado por F. M. Danson y S. E. Plummer). Chichester, John Wiley & Sons: 143-156.

Story, M. y Congalton, R. G. (1986): «Accuracy assessment: A user's perspective», *Photogrammetric Engineering and Remote Sensing*, 52: 397-399.

Story, M. H. y Campbell, J. B. (1986): «The effect of training data on classification accuracy», *ACSM-ASPRS Convention. Technical Papers*: 370-379.

Stow, D.; Niphadkar, M. y Kaiser, J. (2005): «MODIS-derived visible atmospherically resistant index for monitoring chaparral moisture content», *International Journal of Remote Sensing*, 26: 3867-3873.

Strahler, A. H. (1980): «The use of prior probabilities in maximun likelihood classification of remotely sensed data», *Remote Sensing of Environment*, 10: 135-163.

— (1981): «Stratification of natural vegetation for forest and rangeland inventory using Landsat digital imagery and collateral data», *International Journal of Remote Sensing*, 2: 15-41.

Strahler, A. H.; Logan, T. L. y Bryant, N. A. (1978): «Improving forest cover classification accuracy from Landsat by incorporating topographic information», *12th International Symposium on Remote Sensing of Environment*, Ann Arbor, Michigan: 927-941.

Strahler, A. H.; Woodcock, C. E. y Smith, J. A. (1986): «On the nature of models in remote sensing», *Remote Sensing of Environment*, 20: 121-140.

Strain, P. y Engle, F. (1993): *Looking at Earth*, Atlanta, Turner Publishing Inc.

Stroppiana, D.; M.; G. J. y Pereira, J. M. C. (2003): «The use of SPOT VEGETATION data in a classification tree approach for burnt area mapping in Australian savanna», *International Journal of Remote Sensing*, 24: 2131-2151.

Swain, P. H. y Davis, S. M. (eds.) (1978): *Remote Sensing: The Quantitative Approach*, Nueva York, McGraw-Hill.

Szekielda, K. H. (1988): *Satellite Monitoring of the Earth*, Nueva York, John Wiley & Sons.

Tameishi, H. (1991): «Fisheries detection using NOAA satellite», en *Applications of Remote Sensing in Asia and Oceania* (editado por S. Murai). Hong Kong, Asian Association on Remote Sensing: 323-332.

Tanre, D.; Deroo, C.; Duhaut, P.; Herman, M.; Morcrette, J. J.; Perbos, J. y Deschamps, P. Y. (1986): *Simulation of the Satellite Signal in the Solar Spectrum (5S)*, Villeneuve d'Asq (France), Laboratoire d'Optique Atmosphérique, Université des Sciences et Techniques Lille,

Tapia, L. (1989): «Derecho espacial y programas de observación de la Tierra», en *La Observación de la Tierra desde el Espacio* (editado por R. Núñez). Santander, Universidad Menéndez Pelayo: 1-15.

Tapiador, F. J. y Casanova, J. L. (2001): «La fusión de datos en teledetección», *Revista Española de Teledetección*, 15: 5-12.

Taubman, D. (2002): «JPEG2000: Image Compression Fundamentals, Standards and Practice», *Journal of Electronic Imaging*, 11: 286-287.

Taylor, B. F.; Dini, P. W. y Kidson, J. W. (1985): «Determination of seasonal and interannual variation in New Zealand pasture growth from NOAA-7 data», *Remote Sensing of Environment*, 18: 177-192.

Teillet, P. M.; Guindon, B. y Goodeonugh, D. G. (1982): «On the slope-aspect correction of multispectral scanner data», *Canadian Journal of Remote Sensing*, 8: 84-106.

Teng, W. L. (1990): «AVHRR monitoring of U.S. crops during the 1988 drought», *Photogrammetric Engineering and Remote Sensing*, 56: 1143-1146.

Terhalle, U. y Bodechtel, J. (1986): «Landsat TM data enhancement technique for mapping arid geomorphic features», *ISPRS/RSS Symp. Mapping from Modern Imagery*, Edimburgo, Remote Sensing Society: 725-729.

Thomas, I. L. (1980): «Spatial post-processing of spectrally-classified Landsat data», *Photogrammetric Engineering and Remote Sensing*, 46: 1201-1206.

Thomas, I. L.; Benning, V. M. y Ching, N. P. (1987*a*): *Classification of Remotely Sensed Images*, Bristol, Adam Hilger.

Thomas, I. L.; Ching, N. P.; Benning, V. M. y D'Aguanno, J. A. (1987*b*): «A review of multi-channel indices of class separability», *International Journal of Remote Sensing*, 8: 331-350.

Thomas, R.; Rignot, E.; Casassa, G.; Kanagaratnam, P.; Acuna, C.; Akins, T.; Brecher, H.; Frederick, E.; Gogineni, P. y Krabill, W. (2004): «Accelerated Sea-Level Rise from West Antarctica», *Science*, 306: 255-258.

Tian, Q.; Tong, Q.; Pu, R.; Guo, X. y Zhao, C. (2001): «Spectroscopic determination of wheat water status using 1650–1850 nm spectral absorption features», *International Journal of Remote Sensing*, 22: 2329-2338.

Tindal, M. A. (1978): *Educator's Guide for Mission to Earth: Landsat Views the World*, Greenbelt, Maryland, NASA, Goddard Space Flight Center.

Todd, W. J.; Gehring, D. G. y Haman, J. F. (1980): «Landsat wildland mapping accuracy», *Photogrammetric Engineering and Remote Sensing*, 46: 509-520.

Togliatti, G. (1986): «LFC: The second generation photogrammetric camera for space photography», *ESA/EaRSEL Symposium on Europe from Space*.

Toll, D. L. (1984): «An evaluation of simulated Thematic Mapper data and Landsat MSS data for discriminating suburban and regional land use and land cover», *Photogrammetric Engineering and Remote Sensing*, 50: 1713-1724.

Tomlin, D. (1990): *Geographic Information Systems and Cartographic Modeling*, Englewood Cliffs, Prentice Hall.

Tompkins, S.; Mustard, J. F.; Pieters, C. M. y Forsythe, D. W. (1997): «Optimization of end members for spectral mixture analysis», *Remote Sensing of Environment*, 59: 472-489.

Toutin, T. y Beaudoin, M. (1995): «Real-time extraction of planimetric and altimetric features from digital stereo SPOT data using a digital video plotter», *Photogrammetric Engineering and Remote Sensing*, 61: 63-68.

Toutin, T.; Redmond, A.; Hoeppner, E.; Hoja, D. y King, C. (1998): «Radarsat and DEM Data Fusion for 3D Visualization over the Reunion Island for Geoscientific Applications», *Fusion of Earth Data: merging point measurements, raster map and remotely sensed images*, Antipolis, France: 75-84.

Townshend, J. y Justice, C. (1981): «Information extraction from remotely sensed data. A user view», *International Journal of Remote Sensing*, 2: 313-329.

Townshend, J.; Justice, C.; Li, W.; Gurney, C. y McManus, J. (1991): «Global land cover classification by remote sensing: present capabilities and future possibilities», *Remote Sensing of Environment*, 35: 243-255.

Townshend, J. R. G. (1980): *The spatial resolving power of Earth resources satellites: a review*, Maryland, NASA, Goddard Spaceflight Center, Tech. Memorandum 82020.

Townshend, J. R. G. y Justice, C. O. (2002): «Towards operational monitoring of terrestrial systems by moderate-resolution remote sensing», *Remote Sensing of Environment*, 83: 351-359.

Townshend, J. R. G.; Justice, C. O.; Gurney, C. y McManus, J. (1992): «The impact of misregistration on change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 30: 1054-1060.

Tricart, J. (1981): «Géomorphologie et quaternaire d'apres une image R.B.V.: La vallee du Sénégal entre Bogué et Podor (Senegal, Mauritanie)», *Annales de Géographie*, 90: 284-310.

Trigg, S. y Flasse, S. (2001): «An evaluation of different bi-spectral spaces for discriminating burned shrub-savannah», *International Journal of Remote Sensing*, 22: 2641-2647.

Trishchenko, A. P. (2006): «Solar irradiance and brightness temperature for SWIR channels of AVHRR and GOES imagers», *Journal of Atmospheric and Oceanic Technology*, 23: 198-210.

Trolier, L. J. y Philipson, W. R. (1986): «Visual analysis of Landsat Thematic Mapper images for hydrologic land use and cover», *Photogrammetric Engineering and Remote Sensing*, 52: 1531-1538.

Tso, B. y Mather, P. (2001): *Classification Methods for Remote Sensed Data*, Londres, Taylor & Francis.

Tsuchiya, K.; Arai, K. y Igarashi, T. (1987): «Marine observation satellite», *Remote Sensing Reviews*, 3: 59-103.

Tucker, C. J. (1979): «Red and photographic infrared linear combinations for monitoring vegetation», *Remote Sensing of Environment*, 8: 127-150.

Tucker, C. J.; Townshend, J. R. G. y Goff, T. E. (1985): «African land-cover classification using satellite data», *Science*, 227: 369-375.

Tucker, C. J.; Yung, I. Y.; Keeling, C. D. y Gammon, R. H. (1986): «Relationship between atmospheric CO_2 variations and a satellite-derived vegetation index», *Nature*, 319: 195-199.

Tucker, C. J.; Newcomb, W. W. y Dregne, H. E. (1994): «AVHRR data sets for determination of desert spatial extent», *International Journal of Remote Sensing*, 15: 3547-3565.

Turner, M. G. (1989): «Landscape ecology: the effect of pattern on process», *Annual Review of Ecology and Systematics*, 20: 171-197.

Turner, M. G.; Hargrove, W. W.; Gardner, R. H. y Romme, W. H. (1994): «Effects of Fire on Landscape Heterogeneity in Yellowstone-National-Park, Wyoming», *Journal of Vegetation Science*, 5: 731-742.

Unninayar, S. (1988): «The global system, observing and monitoring change. Data problems,

data management and databases», en *Building Databases for Global Science* (editado por H. Mounsey). Londres, Taylor & Francis: 357-377.

Ustin, S. L. y Trabucco, A. (2000): «Using hyperspectral data to assess forest structure», *Journal of Forestry*, 98: 47-49.

Ustin, S. L.; Roberts, D. S.; Pinzón, J.; Jacquemoud, S.; Gardner, M.; Scheer, B.; Castañeda, C. M. y Palacios-Orueta, A. (1998): «Estimating canopy water content of chaparral shrubs using optical methods», *Remote Sensing of Environment*, 65: 280-291.

Valor, E. y Caselles, V. (1996): «Mapping Land Surface Emissivity from NDVI: Application to European, African, and South American Areas», *Remote Sensing of Environment*, 57: 167-184.

Van Der Werf, G. R.; Randerson, J. T.; Giglio, L.; Collatz, G. J.; Kasibhatla, P. S. y Arellano, A. F. (2006): «Interannual variability in global biomass burning emissions from 1997 to 2004», *Atmospheric Chemistry and Physics*, 6: 3423-3441.

Van Leeuwen, W. J. D.; Huete, A. R. y Laing, T. W. (1999): «MODIS Vegetation Index Compositing approach: a prototype with AVHRR data», *Remote Sensing of Environment*, 69: 264-280.

Van Wagner, C. E. (1974): *Structure of the Canadian Forest Fire Weather Index*, Ottawa, Canadian Department of Environment. Canadian Forestry Service, 1333.

Vargas, F. (2000): *Seguimiento de procesos de deforestación en la reserva de Ticoporo (Llanos occidentales de Venezela) mediante análisis multitemporal de imágenes de satélite*, Departamento de Geografía, Alcalá de Henares, Universidad de Alcalá.

Vaughan, P. (2001): *Estimación de contenido de humedad de la vegetación mediante radiometría de campo*, Departamento de Geografía, Alcalá de Henares, Universidad de Alcalá: 105.

Vega-García, C. y Chuvieco, E. (2006): «Applying local measures of spatial heterogeneity to Landsat-TM images for predicting wildfire occurrence in Mediterranean landscapes», *Landscape Ecology*, 21: 595-605.

Vega-García, C.; Lee, B. y Wooddard, T. (1996): «Applying neural network technology to human-caused wildfire occurence prediction», *AI Applications*, 10: 9-18.

Verbyla, D. (1995): *Satellite Remote Sensing of Natural Resources*, Boca Raton, Lewis Publishers.

Verdin, J. P. (1985): «Monitoring water quality conditions in a large Western reservoir with Landsat imagery», *Photogrammetric Engineering and Remote Sensing*, 51: 343-353.

Verhoef, W. y Peteri, P. W. (1984): «Digital mosaic of the Netherlands from Landsat MSS data in natural colour», *International Journal of Remote Sensing*, 5: 749-751.

Vermote, E.; Tanré, D.; Deuzé, J. L.; Herman, M. y Morisette, J. J. (1997): *Second Simulation of the Satellite Signal in the Solar Spectrum (6S)*, Greenbelt, MD, NASA Goddard Space Flight Center Code 923,

Verstraete, M. M. (1994): «Retrieving canopy properties from remote sensing measurements», en *Imagining Spectrometry, a tool for Environmental Observations* (editado por J. Hill y J. Megier). Bruselas, Comunidad Europea, ECSC, EEC: 109-123.

Verstraete, M. M. y Pinty, B. (1996): «Designing optimal spectral indexes for remote sensing applications», *IEEE Transactions on Geoscience and Remote Sensing*, 34: 1254-1265.

Vidal, A.; Pinglo, F.; Durand, H.; Devaux-Ros, C. y Maillet, A. (1994): «Evaluation of a temporal fire risk index in Mediterranean forest from NOAA thermal IR», *Remote Sensing of Environment*, 49: 296-303.

Viedma, O.; Meliá, J. y Chica-Olmo, M. (1999): «Análisis espacial de los efectos del fuego sobre matorrales mediterráneos mediante semivariogramas aplicados a imágenes Landsat 5 TM», *Teledetección. Avances y Aplicaciones*, Albacete, España, Asociación Española de Teledetección: 239-243.

Viovy, N.; Arino, O. y Belward, A. S. (1992): «The best index slope extraction (BISE): a method for reducing noise in NDVI time-series», *International Journal of Remote Sensing*, 13: 1585-1590.

Vogelman, J. E. (1990): «Comparison between two vegetation indices for measuring different types of forest damage in the North-Eastern United States», *International Journal of Remote Sensing*, 12: 2281-2297.

Wald, L. (1999): «Some Terms of Reference in Data Fusion», *IEEE Transactions on Geoscience and Remote Sensing*, 37: 1190-1193.

Walsh, S. J.; Butler, D. R. y Malanson, G. P. (1998): «An overview of scale, pattern, process relationships in geomorphology: a remote sensing and GIS perspective», *Geomorphology*, 21: 183-205.

Wan, Z.; Zhang, Y.; Zhang, Q. y Li, Z.-L. (2002): «Validation of the land-surface temperature products retrieved from Terra Moderate Resolution Imaging Spectroradiometer data», *Remote Sensing of Environment*, 83: 163-180.

Wang, F. (1990): «Improving remote sensing image analysis through fuzzy information representation», *Photogrammetric Engineering and Remote Sensing*, 56: 1163-1169.

— (1993): «A knowledge-based vision system for detecting land changes at urban fringes», *IEEE Transactions on Geoscience and Remote Sensing*, 31: 136-145.

Wang, L. y He, D. C. (1990): «A new statistical approach for texture analysis», *Photogrammetric Engineering and Remote Sensing*, 56: 61-66.

Weber, J. A. y Ustin, S. L. (1991): «Diurnal water relations of walnut trees: implications for remote sensing», *IEEE Transactions on Geoscience and Remote Sensing*, 29: 864-874.

Webster, T. L.; Forbes, D. L.; Mackinnon, E. y Roberts, D. (2006): «Flood-risk mapping for storm-surge events and sea-level rise using lidar for southeast New Brunswick», *Canadian Journal of Remote Sensing*, 32: 194-211.

Weiss, M.; Troufleau, D.; Baret, F.; Chauki, H.; Prévot, L.; Olioso, A.; Bruguier, N. y Brisson, N. (2001): «Coupling canopy functioning and radiative transfer models for remote sensing data assimilation», *Agricultural and Forest Meteorology*, 108: 113–128.

Welch, R. y Usery, E. L. (1984): «Cartographic accuracy of Landsat-4 MSS and TM image data», *IEEE Transactions on Geoscience and Remote Sensing*, GE22: 281-288.

Westman, C. (1994): «Estimating canopy biochemistry through imaging spectrometry», en *Imagining Spectrometry, a tool for Environmental Observations* (editado por J. Hill y J. Megier). Bruselas, Comunidad Europea, ECSC, EEC: 57-69.

Westman, C. A.; Aber, J. D.; Peterson, D. L. y Melillo, J. M. (1988): «Remote sensing of canopy chemistry and nitrogen cycling in temperate forest ecosystems», *Nature*, 335: 154-156.

Westman, W. E. y Price, C. V. (1988): «Spectral changes in conifers subjected to air pollution and water stress: experimental studies», *IEEE Transactions on Geoscience and Remote Sensing*, 26: 11-20.

Wilkie, D. S. y Finn, J. T. (1996): *Remote Sensing Imagery for Natural Resources Monitoring*, Nueva York, Columbia University Press.

Wilkinson, G. G. y Mégier, J. (1990): «Evidential reasoning in a pixel classification hierarchy. A potential method for integrating classifiers and expert system rules based on geographic context», *International Journal of Remote Sensing*, 11: 1963-1968.

Williamson, R. A. (2001): «Remote sensing policy and the development of commercial remote sensing», en *Commercial Observation Satellites. At the leading edge of Global transparency* (editado por J. C. Baker, K. M. O'Connell y R. A. Williamson). Santa Monica, RAND - ASPRS: 37-52.

Woldai, T. (1983): «Landsat and SIR-A interpretation of the Kalpin Chol and Chong Korum mountains of China», *ITC Journal*, 83: 250-252.

Woodcock, C. E. y Strahler, A. H. (1987): «The factor of scale in remote sensing», *Remote Sensing of Environment*, 21: 311-332.

Woodcock, C. E.; Strahler, A. H. y Jupp, D. L. (1988*a*): «The use of variograms in remote sensing: II. Real digital images», *Remote Sensing of Environment*, 25: 349-379.

— (1988*b*): «The use of variograms in remote sensing: I. Scene models and simulated images», *Remote Sensing of Environment*, 25: 323-348.

Wu, S. T. (1980): «An improvement in land cover classification achieved by merging microwave data with Landsat multispectral scanner data», *Photo-Interpretation*, 80: 1-18.

Yebra, M.; Chuvieco, E. y Riaño, D. (2008): «Estimation of live Fuel Moisture Content from MODIS images for fire risk assessment», *Agricultural and Forest Meteorology*, 148: 523-536.

Yocky, D. A. (1996): «Multiresolution wavelet decomposition image merger of Landsat Thematic Mapper and SPOT pancromatic data», *Photogrammetric Engineering and Remote Sensing*, 62: 1067-1084.

Zarco-Tejada, P. J.; Miller, J. R.; Mohamed, G. H.; Noland, T. L. y Sampson, P. H. (1999): «Utilización de modelos de reflectancia como nexo entre muestras foliares y la cobertura forestal: aplicación a datos hiperespectrales», *Revista Española de Teledetección*, 12: 21-32.

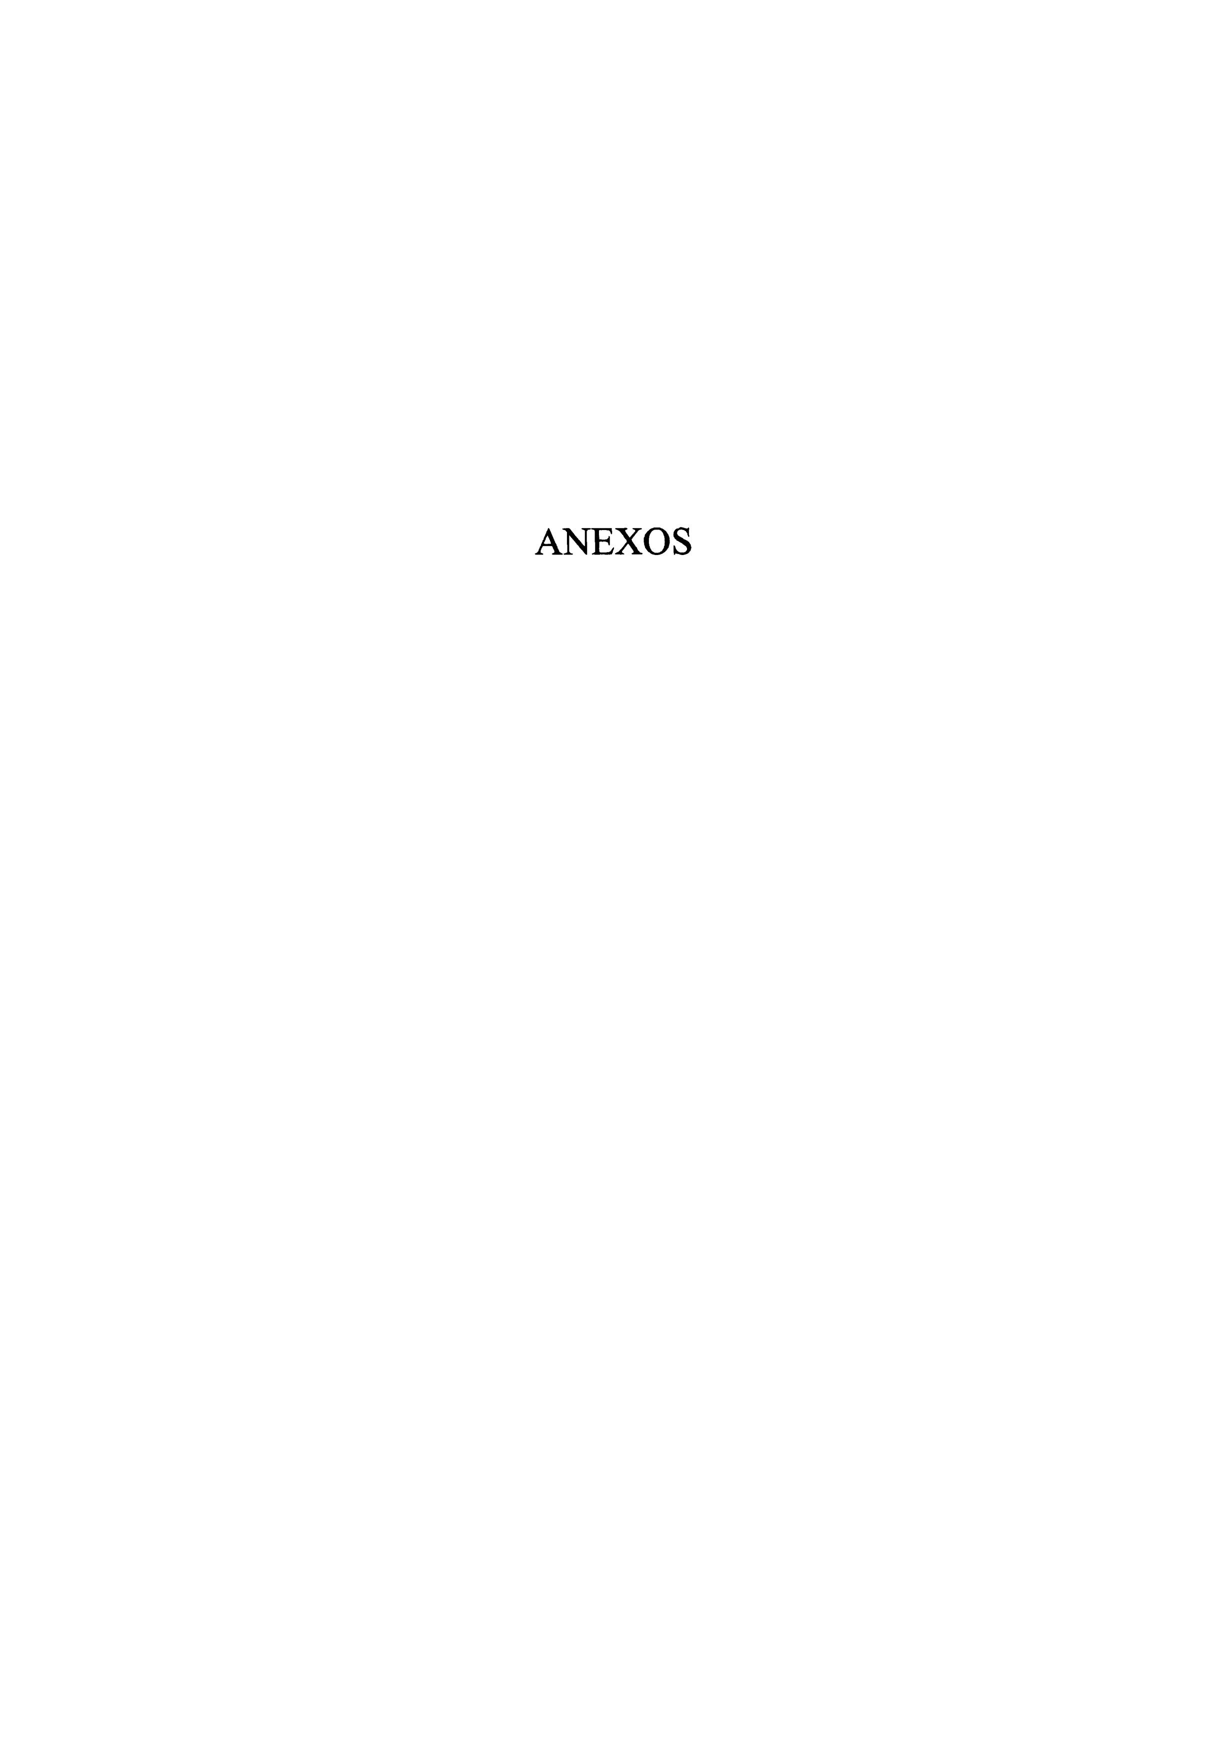
Zarco-Tejada, P. J.; Miller, J. R.; Noland, T. L.; Mohammed, G. H. y Sampson, P. H. (2001): «Scaling-Up and Model Inversion Methods with Narrowband Optical Indices for Chlorophyll Content Estimation in Closed Forest Canopies with Hyperspectral Data», *IEEE Transactions on Geoscience and Remote Sensing*, 39: 1491-1507.

Zarco-Tejada, P. J.; Rueda, C. A. y Ustin, S. L. (2003): «Water content estimation in vegetation with MODIS reflectance data and model inversion methods», *Remote Sensing of Environment*, 85: 109-124.

Zhan, X.; Sohlberg, R. A.; Townshend, J. R. G.; Dimiceli, C.; Carroll, M. L.; Eastman, J. C.; Hansen, M. C. y Defries, R. S. (2002): «Detection of land cover changes using MODIS 250 m data», *Remote Sensing of Environment*, 83: 336-350.

Zhang, Q. F.; Pavlic, G.; Chen, W. J.; Fraser, R.; Leblanc, S. y Cihlar, J. (2005): «A semi-automatic segmentation procedure for feature extraction in remotely sensed imagery», *Computers & Geosciences*, 31: 289-296.

Zhou, G.; Song, C.; Simmers, J. y Cheng, P. (2004): «Urban 3D GIS From LIDAR and digital aerial images», *Computers and Geosciences*, 30: 345-353.



ANEXOS

Anexo 1

ABREVIATURAS UTILIZADAS EN EL MANUAL

AATSR	*(Advanced Along Track Scanning Radiometer)*
ACP	(Análisis de Componentes Principales)
ADI	(Análisis Digital de Imágenes)
ALI	*(Advanced Land Imager)*
ALME	(Análisis Lineal de Mezclas Espectrales)
ALOS	*(Advanced Land Observing System)*
AMI	*(Active Microwave Instrument)*
ARVI	*(Atmospherically Resistant Vegetation Index)*
ASAR	*(Advanced Synthetic Aperture Radar)*
ASTER	*(Advanced Spaceborne Thermal Emisión and Reflection Radiometer)*
ATS	*(Applications Technology Satellite)*
ATSR	*(Along Track Scanning Radiometer)*
AVHRR	*(Advanced Very High Resolution Radiometer)*
AVIRIS	*(Airborne Visible/Infrared Imaging Spectrometer)*
BIL	*(Band Interleaved by Line)*
BIP	*(Band Interleaved by Pixel)*
BRDF	*(Bi-directional Reflectance Distribution Factor)*
BSQ	*(Band Sequential)*
CASI	*(Compact Airborne Spectrographic Imager)*
CCD	*(Charge Couple Devices)*
CERES	*(Clouds and the Earth's Radiant Energy System)*
CF	(Coeficientes de Filtraje)
CH	(Contenido de Humedad)
CLUT	*(Color Look Up Table)*
CNES	*(Centre National d'Etudes Spatiales, Francia)*
CRT	*(Cathode Ray Tube)*
CZCS	*(Coastal Zone Color Scanner)*
DAAC	*(Distributed Active Archive Center Alliance)*
DAIS	*(Digital Airborne Imaging Spectrometer)*
DLR	*(Deutschen Zentrum für Luft-un Raumfahrt, Alemania)*
DMSP	*(Defense Meteorological Satellite Program)*
EIFOV	*(Effective Instantaneous Field of View)*
EL	(Error Longitudinal)
EO-1	*(Earth Observing - 1)*
EOS	*(Earth Observing System)*
EOSDIS	*(Earth Observation System Data and Information System)*

ERBE	*(Earth Radiation Budget Experiment)*
ERE	*(Effective Resolution Element)*
EREP	*(Earth Resources Experiment Package)*
ERS	*(European Remote Sensing Satellite)*
ESA	*(European Space Agency)*
ESC	*(Electronic Sill Camera)*
ET	(Evapotranspiración)
ETC	*(Earth Terrain Camera)*
ETM	*(Enhanced Thematic Mapper)*
EWT	*(Equivalent Water Thickness)*
FBA	*(Foreground / Background Analysis)*
FTP	*(File Transfer Protocol)*
GAC	*(Global Area Coverage)*
GARP	*(Global Atmospheric Research Programme)*
Gb	(Gigabyte, 10^9 bytes)
GCP	*(GCPWorks)*
GEMI	*(Global Environment Monitoring Index)*
GHz	(Gigaherztios, 10^9 Hz)
GIF	*(Graphics Interchange Format)*
GMT	*(Greenwich Meridian Time)*
GOES	*(Geostationary Operational Environmental Satellite)*
GOME	*(Global Ozone Monitoring Experiment)*
GOMOS	*(Global Ozone Monitoring by Occultation of Stars)*
GPS	*(Global Positioning System)*
GVI	*(Global Vegetation Index)*
HCMR	*(Heat Capacity Mapping Radiometer)*
HIRIS	*(High Resolution Imaging Spectrometer)*
HIRS/3	*(High Resolution Infrared Radiation Sounder)*
HRPT	*(High Resolution Picture Transmission)*
HRV	*(Haute Resolution Visible)*
Hz	(Hertzio)
IAE	(Índice de Acuerdo Espectral)
IFOV	*(Instantaneous Field Of View)*
IGBP	*(International Geosphere Biosphere Program)*
IHS	*(Intensity, Hue, Saturation)*
INPE	(*Instituto Nacional de Pesquisas Espaciais*, Brasil)
IRC	(Infrarrojo Cercano, situado entre 0,7 y 1,3 m)
IRS	*(Indian Remote Sensing Satellite)*
IRT	(Infrarrojo Térmico, situado entre 8 y 14 mm)
IV	(Índices de Vegetación)
IW	*(Image Works)*
JPEG	*(Joint Photographic Expert's Group)*
JPL	*(Jet Propulsion Laboratory)*
Kb	(Kilobyte, 10^3 bytes)
LAC	*(Local Area Coverage)*
LAD	*(Leaf Angle Distribution)*
LAI	*(Leaf Area Index)*
LFC	*(Large Format Camera)*
LISS	*(Linear Imaging Self Scanning)*
Mb	(Megabyte, 10^6 bytes)

MDE (Modelo Digital de Elevación)
MERIS *(Medium Resolution Imaging Spectrometer)*
MISR *(Multi-Angle Imaging Spectroradiometer)*
MNF *(Minimum Noise Fraction)*
MODIS *(Moderate-Resolution Imaging Spectroradiometer)*
MOPITT *(Measurements of Pollution In The Troposphere)*
MOS *(Marine Observation Satellite)*
MSG *(Meteosat Second Generation)*
MSS *(Multispectral Scanner)*
MSU *(Microwave Sounding Unit)*
MUC (Mínima Unidad Cartografiable)
NASA *(National Aeronautics and Space Administration)*
NASDA (*National Space Development Agency,* Japón)
ND (Nivel Digital, de cada píxel)
NDII *(Normalized Difference Infrared Index)*
NDVI *(Normalized Difference Vegetation Index)*
NGDC (*National Geophysical Data Center,* USA)
NOAA *(National Oceanic and Atmospheric Administration Satellite)*
NPOESS *(National Polar-orbiting Operational Environmental Satellite System)*
NRSA (*National Remote Sensing Agency,* India)
NV (Niveles Visuales)
OLS *(Operational Linescan System)*
OPS *(Optical Sensor)*
PDUS *(Primary Data User Stations)*
PNG *(Portable Network Graphics)*
POAM *(Polar Ozone and Aerosol Measurement)*
POLDER *(Polarization and Directionality of the Earth's Reflectance)*
PPI *(Pixel Purity Index)*
PPU *(Patch per Unit)*
RBV *(Return Beam Vidicon)*
RMSE *(Root Mean Squared Error)*
RNA (Redes Neuronales Artificiales)
RVA (Rojo, Verde, Azul)
SAIL *(Scattered by Arbitraily Inclined Leaves)*
SAM *(Spectral Angle Mapper)*
SAR *(Synthetic Aperture Radar)*
SAVI *(Soil Adjusted Vegetation Index)*
SBUV/2 *(Solar Backscatter UltraViolet Spectral Radiometer)*
SELPER (Sociedad de Expertos Latinoamericanos en Percepción Remota)
SEVIRI *(Spinning Enhanced Visible and Infrared Imager)*
SIG (Sistemas de Información Geográfica)
SIR *(Shuttle Imaging Radar)*
SLA *(Specific Leaf Area)*
SLAR *(Side Looking Airborne Radar)*
SPOT *(Satellite Pour l'Observation de la Terre)*
SRTM *(Shuttle Radar Topography Mission)*
SBUV/2 *(Solar Backscatter UltraViolet Spectral Radiometer),*
SSM/I *(Special Sensor Microwave Imager)*
SSMR *(Scanning Multichannel Microwave Radiometer)*
SSU *(Stratospheric Sounding Unit)*

SWIR	(*Short Wave Infrared*, comprendido entre 1,3 y 2,5mm)
TA	(Temperatura del Aire)
TM	*(Thematic Mapper)*
TOVS	*(Tiros Operational Vertical Sounder)*
TRMM	*(Tropical Rainfall Measuring Misión)*
TS	(Temperatura de Superficie)
TTC	(Transformación *Tasseled Cap*)
VCL	*(Vegetation Canopy Lidar*)
VIIRS	*(Visible/Infrared Imager/Radiometer Suite)*
VIS	(Visible, con un rango entre 0,4 y 0,7 mm)
XP	*(Xpace)*

ANEXO 2

GLOSARIO[1]

Abertura: Se habla de apertura de un sistema óptico por la relación entre la luz que deja pasar un diafragma y la que obstruye. *Aperture.*

Absorción atmosférica: Indica la eliminación que realiza la atmósfera de distintos tipos de energía, en razón de sus propios componentes, y principalmente del ozono, oxígeno atómico y vapor de agua. *Absorption.*

Activo, Sistema: Se habla de sensores activos, cuando son capaces de emitir sus propias ondas electro-magnéticas, y grabar posteriormente el haz reflejado por el objeto bajo estudio. *Active Systems.*

Albedo: Ver reflectividad.

Aleteo: Es la consecuencia de la rotación de una plataforma sobre su eje longitudinal. *Roll.*

Anotaciones: Diversos elementos gráficos que son incorporados al tratamiento de las imágenes para mejorar su legibilidad.

Banda espectral: Se refiere este término a una selección de longitudes de onda con comportamientos electro-magnéticos similares. *Spectral Band.*

Barrido multiespectral, Equipos de: Se trata de equipos sensores que permiten explorar secuencialmente la superficie de la Tierra, dividiendo la radiación captada en diversas bandas espectrales. *Multiespectral Scanner.*

Bit: Refiere a un dígito del sistema binario.

Byte: Un grupo de ocho bits de datos numéricos.

Cabeceo: Ocurre cuando una nave espacial se inclina a lo largo de su eje de vuelo. *PITCH*

Calibración: Proceso de comparar ciertas medidas específicas con otro instrumento estándar. *Calibration.*

Cámara multibanda: Cámara que expone diferentes áreas a un film, o a más de un film, a través de una lente. Incluye diferentes objetivos, cada uno de los cuales presenta diversos filtros o tipos de película, de tal forma que puede obtenerse la misma porción del terreno en diferentes bandas espectrales. *Multiband Camera.*

Cámara de gran formato: Se trata de un cámara que permite obtener negativos sobredimensionados, 23 × 46 cm, en lugar de los estándar, 23 × 23 cm. Se ha utilizado en diversas misiones del *Space Shuttle*. *Large Format Camera, LFC.*

Campo instantáneo de visión: Este término expresa el ángulo exacto de visión que es de-

1. Los términos se han extraído de distintos manuales de teledetección y diccionarios técnicos. Incluyen algunas modificaciones de los referenciados en ediciones anteriores, considerando los términos que aportamos al *Diccionario de Cartografía* (editado por I. Otero en 1995, Madrid, Ediciones de Ciencias Sociales). Para una relación más detallada puede consultarse esta obra, así como el *Diccionario multilingüe de la SELPER*, publicado en 1989. De gran interés también es el *Glosario Temático de Rees* (1999).

tectado en cada pauta de observación en un sistema de exploración electrónica. Normalmente se mide en grados o micro-radianes y se relaciona con la superficie real abarcada por el detector. *Instantaneous Field of View, IFOV.*

Clasificación digital: Proceso por el que se asigna un píxel de una imagen multiespectral a una de las categorías de la leyenda, generalmente sobre la base de similitudes entre los valores numéricos que las definen. *Pattern Recognition, Digital Classification.*

Clúster: Se habla de cluster o conglomerado cuando los píxeles o elementos de una imagen tienden a formar grupos con similares condiciones espectrales. El agrupamiento automático no supervisado pretende encontrar estos grupos espectrales idóneos como reflejo de los naturalmente existentes en la imagen.

Componentes principales: Es una técnica de tratamiento estadístico que permite condensar una serie de variables en un menor número sobre la base de sus correlaciones mutuas. *Principal Components.*

Conducción: La transferencia de energía electromagnética a través de un material por interacción molecular. *Conduction.*

Contraste: Diferencia de valor o tono entre las áreas más claras y más oscuras de una imagen. *Contrast.*

Correcciones: Indican las operaciones digitales tendentes a eliminar errores en la adquisición de las imágenes, ya sean radiométricos o geométricos.

Cuerpo negro: Se trata de un emisor ideal, que radia el máximo de energía por unidad de superficie en cada longitud de onda y para una temperatura dada. Un cuerpo negro también absorbe toda la energía que sobre él incide. *Blackbody.*

Datos auxiliares: Medidas y observaciones acerca de los objetos, áreas o fenómenos que serán captados por algún medio de teledetección. Pueden ser mapas de ocupación del suelo, litología, análisis químicos, topografía, etc. *Data Reference.*

Densidad, Intervalos de: Indica el proceso de convertir el tono continuo de una imagen en un pequeño número de tonos de gris o color, cada uno de los cuales corresponde a un intervalo digital determinado por el usuario. *Density Slicing.*

Detección de cambios: Cualquier técnica que permita señalar sobre dos o más imágenes multitemporales aquellas zonas que han experimentado transformaciones. *Change Detection.*

Digitalización: El concepto se refiere a cualquier conversión de un documento analógico en formato numérico. *Digitizing.*

Distorsión panorámica: Se produce en los sistemas de barrido por un efecto de diferenciación de escala, en la línea perpendicular a la dirección de vuelo.

Doppler, Efecto: La variación en la frecuencia de una señal, debido al movimiento del transmisor. *Doppler Shift.*

Electro-magnética, Energía: Energía propagada a través del espacio o de otro medio material en un modelo armónico ondulatorio con un componente magnético y otro eléctrico. *Electro-magnetic Energy.*

Emisividad: Proporción entre la energía emitida por un determinado objeto y la que emitiría un cuerpo negro a la misma temperatura. *Emissivity.*

Escáner: Barredor óptico electrónico, que permite convertir un nivel de gris o color en un código numérico. *Scanner.*

Espectro electro-magnético: Se trata de la agrupación de la radiación electromagnética en distintas bandas, definidas por la longitud de onda o la frecuencia, que presentan un comportamiento radiométrico similar. *Electro-magnetic Spectrum.*

Estéreo-radian: Unidad de medida del ángulo sólido. *Stereo-radian.*

Filtros atmosféricos: Cualquier material que ya por absorción o por reflexión modifica selectivamente la radiación transmitida a través de la atmósfera. Los más destacados son el oxígeno, ozono, dióxido de carbono, monóxido de carbono y vapor de agua.

Filtros digitales: Se trata de matrices de coeficientes numéricos que permiten atenuar o acentuar según su finalidad y estructura las gradaciones radiométricas presentes en una imagen. *Digital Filters.*

Frecuencia: Número de ciclos por segundo que pasan por un punto fijo. *Frequency.*

Gausiana, Distribución : Término estadístico que refiere a la disposición de las frecuencias observadas en una variable como ajustadas a la curva normal. *GaussianDistribution.*

Histograma: Una representación gráfica de las frecuencias observadas en una determinada imagen. *Histogram.*

Imagen: Cualquier forma de representación pictórica de los datos no obtenida por medios fotográficos. *Image.*

Inercia térmica: Es la medida de la respuesta de un material a los cambios de temperatura. *Thermal Inertia.*

Infrarrojo: Porción del espectro comprendida entre 0,7 y 100 micras, que tiene gran importancia para estudios de teledetección. Normalmente suele dividirse en infrarrojo cercano, medio y lejano. Este último también se conoce como infrarrojo térmico. *Infrared.*

Infrarrojo color: Se trata de una composición coloreada en la cual se aplican a las bandas espectrales verde, roja e infrarrojo próximo, los colores naturales azul, verde y rojo, respectivamente. Resulta muy útil para detectar cambios en las condiciones de las superficies vegetales. *Color Infrared.*

IRS: *Indian Resources Satellite*, satélite indio de recursos naturales.

JERS: *Japanese Earth Resources Satellite*, satélite japonés de recursos naturales.

Lambertiana, Superficie: Indica un perfecto difusor, que refleja la energía incidente, por igual, en todas las direcciones. *Lambertian.*

Landsat: Serie de satélites construida por la NASA dedicados específicamente a la detección de recursos naturales.

Lídar: Se trata de un sensor activo que trabaja con luz polarizada o láser.

Longitud de onda: Es la medida de la distancia que separa dos valores culminantes entre sucesivas ondas. *Wavelength.*

Máxima verosimilitud: Es un criterio estadístico de clasificación digital de imágenes, por el cual se asigna cada pixel de la imagen a la categoría para la cual posee mayor probabilidad de pertenencia. *Maximum Likelihood.*

Micro-densitómetro: Es un instrumento capaz de traducir una escala de grises a formato digital, mediante la medida de la densidad del film. *Micro-densitometer.*

Micrómetro: Unidad de longitud empleada para medir longitudes de onda de alta frecuencia. Equivale a la millonésima parte de un metro. *Micrometer.*

Micro-ondas: Porción del espectro electromagnético comprendida entre 1 mm y 1 m. *Microwave.*

MIE, Dispersión : Tipo de difusión atmosférica provocada por partículas con similares dimensiones a la longitud de onda de la radiación. *Mie Scattering.*

MOS: *Marine Observation Satellite*, Satélite de recursos naturales diseñado por la agencia espacial japonesa (NASDA), con fines de investigación oceanográfica.

Mosaicos: Se trata de un ensamblaje de distintas imágenes aéreas o espaciales que cubren parte, al menos, del mismo territorio.

Nivel digital: Valor entero que traduce numéricamente la intensidad radiométrica recibida por un sensor óptico-electrónico. *Digital number, Pixel value.*

Orientación angular: Menciona la orientación de un sistema de teledetección con respecto a una referencia geográfica. *Attitude.*

Orto-fotografía: Fotografía corregida de las distorsiones del relieve. *Orthophotography.*

Pasivo, Sistema: Un sistema sensor que detecta la radiación emitida desde el objetivo o reflejada por él. *Pasive Systems.*

Píxel: Derivado del inglés «*picture element*». Es el elemento pictórico más pequeño de las imágenes que es susceptible de ser procesado.

Puntos de control: Se trata de elementos geográficos que pueden ser localizados precisamente en una imagen y en un mapa para ser empleados en la corrección cartográfica de dicha imagen. *Ground Control Point, GCP.*

Radar: Sistema activo de micro-ondas que emite un haz energético sobre la superficie terrestre para luego recoger su reflexión sobre ella. Existen dos tipos de radar: el lateral, y el de apertura sintética. *Radar.*

Radiación: El proceso en el que la energía electromagnética es propagada a través del espacio libre.

Radiancia: Total de energía radiada por unidad de área y por ángulo sólido de medida. *Radiance.*

Radiómetro de micro-ondas: Es un instrumento para medir la energía radiada por las superficies con una longitud de onda de milímetros o centímetros. *Microwave Radiometer.*

Rayleigh, Dispersión : Se produce por partículas atmosféricas mucho más pequeñas en tamaño que la longitud de onda de la radiación. *Rayleigh Scattering.*

Realce de imágenes: Procesos digitales que tienen como fin mejorar la calidad visual de la imagen, mediante el aumento del contraste interno o la creación de nuevas bandas que ilustren mejor sobre sus características originales. *Enhancement.*

Realce de bordes: Proceso particular de realce que tiene como objetivo enfatizar las áreas de transición en una imagen. *Edge Enhancement.*

Reflectividad: Porcentaje de radiación incidente que es reflejada por una superficie bidimensional. *Reflectance.*

Resolución: La resolución es la medida de la habilidad de un sistema sensor para discriminar información dentro de la imagen. Refiere al tamaño de la mínima unidad de información en el terreno (espacial), al número de bandas disponibles (espectral), a los niveles de codificación (radiométrica) o a la frecuencia de cobertura (temporal). *Resolution.*

Ruidos atmosféricos: Refiere este término a las interferencias imprevistas y más o menos aleatorias que introducen una degradación en los datos originales. *Atmospheric Noise.*

Ruido de la escena: Concepto que refiere a la variabilidad espectral hallada en el interior de las distintas clases temáticas. *Scene Noise.*

Sensor: Cualquier instrumento que detecta energía electromagnética, la convierte en una señal y la presenta en forma susceptible de ser aprovechada para su estudio.

Signatura espectral: Forma peculiar de reflejar o emitir energía de un determinado objeto o cubierta. Está afectada por las características físicas o químicas del objeto que interaccionan con la energía electro-magnética, y varía según las longitudes de onda. *Spectral Signature.*

Sistema de información geográfica: Conjunto de programas que permiten almacenar, recuperar, modificar y combinar cualquier tipo de variables georreferenciadas. *Geographic Information Systems.*

Suavizado de imágenes: Operación digital que tiene por objeto obtener una mayor generalización en los resultados.

Teledetección: Es la técnica que permite obtener información sobre un objeto, área o fenómeno a través del análisis de los datos adquiridos por un instrumento que no está en contacto con el objeto, área o fenómeno bajo investigación. *Remote Sensing.*

Termografía: La termografía es la rama de la teledetección que se ocupa de la medición de la temperatura radiada por los fenómenos de la superficie de la Tierra desde una cierta distancia. *Thermography.*

Teselar, Estructura : Sistema de almacenamiento de datos en un SIG que parte de dividir el terreno en una serie de celdillas regulares, sobre las que se codifican las distintas variables que integran el sistema. *Grid-Based GIS.*

Thematic Mapper: Se trata de un equipo de barrido multiespectral bastante sofisticado, que se incorpora a los satélites de recursos naturales Landsat 4 y 5.

Vectorial, Estructura: Forma de almacenamiento de datos en un SIG, en el cual las distintas unidades temáticas se definen por las coordenadas de sus bordes. Una descripción topológica asociada a esa información gráfica permite reconstruir, posteriormente, las variables temáticas asociadas a esos polígonos. *Vector-Based GIS.*

Ventanas atmosféricas: Aquellas porciones del espectro en las cuales la atmósfera ofrece poca atenuación a la radiación electro-magnética. *Atmospheric Window.*

Verdad terreno: Refiere a todas las medidas de magnitudes físicas y muestreos llevados a cabo sobre el área materia de operación. *Ground Truth.*

Vidicon, Sistema: Es un tubo electrónico sensor de imágenes en el cual la imagen es recibida y alimentada sobre la superficie de un fotoconductor que sostiene el barrido electrónico. *Return Beam Vidicon.*

Visualización de datos: Cualquier representación visual de imágenes digitales. Puede realizarse sobre un monitor, un trazador electrostático, láser o impresora de líneas. *Display.*

ANEXO 3

ÍNDICE TEMÁTICO

A

Absorción atmosférica, 83-84, 342
Absortividad, 48-49, 55, 61, 63-66, 68-69, 278, 439
Agua (aplicaciones), 18, 26, 36, 39, 55-56, 59-62, 64-75, 77, 79-85, 118-119, 127, 130, 133, 142-144, 148, 151-152, 155, 165-167, 171, 173-174, 180, 189, 191-192, 195, 213, 215, 219, 232, 239-240, 251-252, 261, 265, 267, 273, 276-279, 299, 308, 325-328, 331-333, 336, 338, 340, 343-345, 350, 353-354, 358, 373-374, 386, 388, 392-393, 398-399, 401, 403, 413, 415, 433, 438, 444, 449, 452, 458, 460-461, 483, 488, 491, 495, 498, 502, 509, 511, 520-521, 523
Alabeo, 264
ALME, 366-376, 382, 429, 488
ALOS, 108, 111, 117, 153-154
Altímetro, 81, 111, 118-120, 150-151, 325
Análisis visual, 174, 177-182, 186, 189, 193-195, 201, 205-206, 208-209, 217, 219, 252, 317, 377, 416, 432, 433, 443, 488, 519
Ángulo cenital solar, 202, 278-279, 281-283, 288, 299
Ángulo de incidencia, 75, 77-81, 89, 113-115, 151-152, 281, 282-284
Ángulo de elevación solar, 177, 186, 272, 281
Ángulo sólido, 48-49
Aqua, 27, 110-111, 123, 144-146
ASTER, 60, 65, 145, 185
Atmósfera, 19, 49, 52-53, 57-58, 74, 82-84, 86, 140, 142-144, 146, 148-149, 151, 265, 272-276, 278, 291, 293, 295, 299, 342, 345, 498
correcciones, 86, 265, 274, 276, 339, 361, 439
influencias, 291, 343
ATS, 143
ATSR, 84, 86, 97, 107, 151, 292-293
Auto-correlación, 266, 464, 488, 491, 495
AVHRR, 72, 93, 97, 107, 134, 140-142, 149, 154, 167, 170-171, 175, 200, 214-215, 226-227, 244, 265, 274, 275, 287, 244, 265, 274-275, 287-288, 290-295, 298-301, 304-305, 324, 328-330, 339, 342, 353, 367, 369, 373, 382, 440-441, 455, 475-478, 485
AVIRIS, 155-156, 359, 362

B

Banda espectral, 50, 67, 128, 213, 217, 361, 439, 444
Bandeado, 255, 265, 267, 268, 269
Barrido, 21, 97, 99, 104-107, 109, 119, 121, 126-130, 140, 143, 146-147, 149-150, 153-154, 203, 235, 264-265, 267, 274, 286, 301, 303-304
BRDF, 277, 285-288, 290, 334
Brillo, 148, 178, 190-193, 205, 215, 219, 221, 243, 252, 292-293, 295, 298, 349, 352-354, 356-358, 438, 448-449

C

Cabeceo, 264
Calibración, 38, 108, 129, 181, 209, 223, 233, 238, 265, 268, 271-273, 277, 292,

299, 327, 342, 361, 378, 438, 440, 498, 500
Cámaras espaciales, 100
gran formato, 100, 102-103
métrica, 100, 102
multibanda, 99
Cambios (detección de), 167, 183, 214, 270, 305, 350, 438, 442, 448, 453, 456, 481, 511-512
Campo instantáneo de visión (ver IFOV), 89, 303
Capacidad térmica, 69, 154
Catálogos bibliográficos, 40
Clasificación digital, 179-180, 201, 254-255, 259, 380, 383-386, 389, 392, 409, 413, 430, 432, 467, 481, 497, 515, 523
no supervisada, 245, 296, 394, 413, 426, 456, 460, 518
supervisada, 456, 460, 518
mixta, 508
borrosa, 427
Clorofila, 36, 59, 61, 65-66, 151, 155, 165-167, 180, 325, 326, 332-333, 336, 340, 426, 461, 481, 483, 498-499, 520-521
Cocientes, 168, 226, 337-338, 345, 446, 447
CLUT (ver tablas de color), 242, 270
Color, 46, 52, 55, 61, 63-64, 85, 91, 93-94, 99, 101, 103-104, 107, 117, 134, 137, 154, 177-178, 190, 193-196, 200, 205, 213, 215, 219, 221, 223, 225, 229-230, 233, 235, 242-246, 248-249, 251-254, 260, 270, 319, 342, 346, 349, 352, 355, 357-358, 379, 431, 443-444, 459
Componentes principales, 168, 195, 226, 346-349, 351, 366, 374, 429, 439, 442-443, 448, 449, 456, 462, 517
Compresión del contraste, 242-244, 251
Congresos, 27, 29-31, 33, 40
Constante dieléctrica, 75, 78, 80
Contexto espacial, 179, 200-201, 220, 299, 385, 416, 421, 456
Contraste, 62-64, 69, 89, 92, 115, 171, 191, 196, 207, 215, 238, 240, 242-246, 248-252, 254, 256, 258-262, 265, 273, 298, 308, 310, 317, 338, 343, 344, 347, 349-350, 353-354, 358, 376, 385, 388, 399, 419, 448-449, 462-463, 465-466, 468-470, 476, 486, 487, 517
Conversión a reflectividad, 272
Corrección, 18, 38, 69, 86, 113, 126, 143, 180, 187, 205-206, 223, 227, 235, 255, 262-263, 265-267, 274-277-281, 283-288, 293, 295, 299-301, 303-307, 309-310, 312-314, 317, 319-321, 338-339, 354, 361, 378, 383-384, 431, 436, 438-441, 450, 496-497, 500, 503, 517-518, 525-526
atmosférica, 86, 265-266, 274, 276-278, 293, 295, 339, 354, 361, 438-439
radiométrica, 187, 262, 266, 378
geométrica, 38, 180, 235, 263, 265, 299-300, 306, 312-314, 317, 320-321, 431, 436, 440-441, 450, 500, 517-518, 525-526
Cuerpo negro, 48-53, 68, 291
Cultivos, 30, 60, 70, 98, 100, 170, 174, 176, 179, 185, 189, 191, 195-196, 201, 204, 213, 215, 219-220, 232, 294, 334, 344, 350, 352, 354, 362, 367, 374, 392, 399, 403, 412-413, 416-417, 421-422, 427, 432-434, 439-440, 442, 487-488, 498, 505-506, 518, 520, 522
CZCS, 107

D

Definición, 17, 32, 88-89, 168, 170, 175, 181, 242, 251, 271, 277, 339, 359, 374, 377, 384, 386-387, 390, 397, 407, 412, 426, 428, 498, 517-518
Deforestación, 13, 37, 98, 117, 141, 341, 369, 373, 382, 434, 445-447, 457, 474, 478
Desarrollo, 13-14, 20-21, 25-28, 30-34, 39-40, 59-60, 63, 117, 131, 137, 156-157, 163-165, 168-169, 175, 197, 214, 231, 235, 327, 352, 380, 451, 491, 494, 513, 515-516, 521
Desertificación, 13, 20, 37, 141, 374, 433, 478
Detectores, 21, 89, 105-108, 127-129, 132, 265, 267-269
Difusividad térmica, 69
Digitizador, 234-235, 389, 515
Dinamismo estacional, 57, 486
Disco magnético, 229, 237, 243
Dispersión atmosférica, 84-85, 237, 275, 278
Dispersómetro, 81-82, 111, 118, 150, 154
Diversidad, 26, 146, 168, 389, 399, 461-463, 473-478, 505
DMSP, 107, 110, 149-150
Dominancia, 473-474

E

EARTHNET, 187
Efecto Doppler, 113
Emisión atmosférica, 86
Emisividad, 48-52, 68-69, 71, 165, 291, 293-295, 298, 486
Emitancia radiante, 51
Entrenamiento (fase de), 386-387, 396-397, 412, 417, 502
Envisat, 30, 77-78, 81, 84, 117 151, 156, 208, 359
EO-1, 91, 108, 144, 156, 268
Equipos de tratamiento digital, 227
Errores (en la clasificación), 427, 459, 466, 485, 488
 fuentes de, 263-264, 300, 482, 484, 521
 comisión, 297, 383, 405, 412, 443, 456, 483, 504, 512
 omisión, 297, 443, 456, 483, 501, 504, 512
ERS, 22, 25, 30, 73, 80, 82, 84, 93, 96-97, 107, 115-118, 149-152
ERTS (ver Landsat), 24, 125, 187
Espectro electro-magnético, 46-47
Especular, 56, 66, 74-75, 77-78, 81
Evapotranspiración, 70-72, 165, 296, 324-325, 340
Expansión del contraste, 242, 245-246, 252
Explorador de barrido, 106, 127, 153
Explorador de empuje, 107

F

Falso color, 99, 193-194, 213, 219, 221, 252, 358
Fiabilidad, 89, 107, 115, 182, 312, 377, 381, 406, 408, 455, 459-460, 482-485, 488, 495, 498, 501, 503-505, 507-509, 511-512, 520
Filtros digitales, 116, 254-255
 Modales, 458, 517, 527
 De paso bajo, 254-255, 258-259, 420
 De paso alto, 254, 256, 259-260
Firma espectral, 58-59, 201, 208
Fluorescencia, 119
Formatos, 18, 37-38, 92, 100, 102-104, 106, 128, 140, 163, 177-178, 180, 186-188, 223, 226-227-229, 231-233, 299, 431, 513, 517, 520, 523-524
 BSQ, 227-228, 233
 BIL, 227-228, 233
 BIP, 227-228
Fractales, 463-464
Fusión de datos, 38, 129, 376-377, 382, 527

G

Geobotánica, 64
GEMI, 342-343
Gemini, 23, 100
Giro lateral, 264
Global, 25-26, 34, 36, 38, 41, 51, 53, 68, 71, 84, 88-89, 102, 120, 124-125, 131, 134, 141-142, 144-145, 149, 154,164, 171, 175, 207, 258, 265, 291, 294, 301, 303, 305, 327, 340-343, 350, 368, 376, 390, 403, 414, 420, 424, 429, 440, 442, 467, 470, 484, 490, 494, 501, 503-504, 505, 507, 508, 512, 516, 520-521
GOES, 27, 84, 89, 96, 123, 143
GOMOS, 84

H

HCMM, 25, 107
Hielo, 67, 74, 81, 110, 121, 151
Hiperespectral, 25, 59, 91, 106, 147, 151, 156, 176, 241, 252, 329, 332, 346, 359, 361-362-363, 365-366, 372, 377, 392
 sensores, 147, 151, 156, 176, 252, 332, 359, 377
 técnicas, 359
Histograma, 120, 233, 237-239, 245-249, 251, 268-270, 278, 401, 445, 454-456, 463, 469, 471
HRV (ver SPOT), 91, 108, 132-133, 154, 170-171, 185, 194, 203, 265, 274, 277, 303, 339, 382, 485
Hyperion, 91-92, 108, 156, 359

I

IFOV, 89, 303
IHS, 355, 357-360, 378, 379
IKONOS, 28, 89, 93, 95, 108, 123, 137-138,

162, 170, 175, 176, 197-198, 227, 244, 274-275, 377
Impresoras, 230, 515
Incendios forestales, 36, 41, 60, 84-85, 98, 141, 164-165, 176, 341, 366, 369, 447
Índices de vegetación, 63, 147, 254, 326, 337, 340, 439, 441, 445, 447, 456, 462, 470, 475, 517
Inercia térmica, 69-71
Infrarrojo, 20-21, 36, 46, 55, 60-65, 67-68, 70, 83, 86, 91, 93, 99, 101, 104, 107-108, 119, 127, 133, 141-143, 149-151, 153-154, 191-192, 194-196, 203, 252, 291, 325, 330, 339, 342, 343, 353, 378, 452
  cercano, 46, 55, 61-65, 67, 91, 93, 99, 104, 119, 127, 133, 141, 153-154, 191-192, 195, 203, 339, 342-343, 378, 452
  medio, 36, 46, 55, 62, 67, 83, 143, 353
  térmico, 36, 46, 60, 67-68, 70, 83, 86, 108, 141, 143, 149-150, 153-154, 291, 325
Intensidad, 48, 50, 64, 69, 75, 85, 111, 118-119, 178, 187, 189, 191, 193, 195, 213, 223, 225, 240, 243, 252-254, 285, 288, 357-358, 360, 362, 378-379, 381, 429, 432, 447, 452-454
  radiante, 48, 69, 191
Interferometría, 118, 165, 204, 325
Interpolación, 34, 71, 167, 236, 278, 305, 315-319, 324, 521, 525-527
Inventario, 24, 30, 80, 137, 141, 162, 167, 170-176, 180-181, 183, 219, 354, 369, 380-384, 388, 410, 414, 429-430, 432-434, 438, 447, 464, 467, 482, 515, 520, 522
Irradiancia radiante, 48-49, 51, 53, 58, 144, 272-275, 279, 282, 284, 287
IRS, 25, 108, 123, 135-137, 175, 185, 194, 208, 273, 303

J

JERS, 73, 108, 112, 117, 152, 154

K

Kappa, 459, 505
Kirchoff (Ley de), 68

L

Lambertiano, 56-57, 272, 274, 276, 283-285
Landsat, 22, 24, 27-28, 34, 41, 66, 93, 96-97, 103, 107, 109, 123-132, 144, 150, 154, 163-164, 166, 170-171, 185-188, 194-195, 203, 206-209, 217, 219, 232, 239, 264, 267, 272-273, 277, 280, 292, 303, 320, 328, 330, 339, 354, 377, 381, 436, 458, 463, 466, 475, 485, 497, 502, 509-510, 515, 519
Legislación, 33
Leyenda, 170, 172-175, 181, 196, 219, 367, 387-389, 393, 396-398, 403, 405, 407, 428, 431, 457, 460, 483-485, 502, 507, 521
Lídar, 25, 39, 87, 119-121, 165, 204, 325, 490
Longitud de onda, 45-46, 49-50, 52, 55-56, 65, 70, 73, 75-76, 78, 80, 85, 89, 110-111, 118, 145, 152, 197, 273, 279, 282, 287-288, 293, 298, 338, 357, 362

M

Máscaras, 235, 456
Matriz de confusión, 482-483, 501, 503, 505, 507-509, 511-512
Máxima probabilidad, 404, 407, 411-413, 419, 427-428, 433
Meteosat, 29, 82, 84, 89, 96, 123, 143-144, 154, 165, 175
Micro-ondas, 20, 46, 52, 56, 73-74, 78, 80-81, 83, 87, 99-100, 110-111, 118, 137, 150-151, 154, 325
Mínima distancia, 336, 397, 404-405, 407
Modelo digital de elevaciones, 308, 416, 502
Modelos de transferencia radiativa, 276-277
MODIS, 34, 66, 92-93, 142, 145, 147-148, 156, 163, 170-171, 175-176, 207-208, 226-227, 265, 276, 290, 292, 299-300, 328, 339, 343, 359, 369, 373, 440-441, 454, 485, 509
MOS, 25, 108, 153
MSS, 107, 126-127-131, 154, 166, 170, 186, 194, 200, 217-218, 264, 267-268, 273, 308, 339, 352-353, 377, 382, 448
Muestreo, 36, 141, 167, 182, 233, 324, 328,

382, 387, 391-392, 451, 466, 481-482, 484, 490-497, 500, 503, 507, 511

N

NDVI, 141, 215, 294, 330-331, 339-344, 381, 439, 441-442, 444-447, 455, 464, 475-478
Nimbus, 74, 107, 109-110, 149
Nivel digital (ND), 223, 225, 266, 272
NOAA, 27, 34, 38, 72, 93, 96-97, 107, 131-132, 134, 139-144, 146, 149, 154, 170, 214-215, 227, 244, 274, 290, 301, 328, 330, 341, 475
Nubes (máscara de), 456

O

Órbitas, 123-124, 126, 132, 140, 144-145, 176, 204, 290, 434
Ortoimagen (ver corrección geométrica), 317
Ozono, 13, 34-35, 82-84, 133, 142, 143, 151, 154, 275, 279

P

Paralelepípedos, 404-406
Patrón espacial, 183, 203-204, 439, 461-463, 484, 491
Perfiles, 154, 167, 240-241, 258, 276-277, 350, 439, 463, 475, 487
Píxel, 89-90, 93, 103, 106-107, 110-111, 113, 119-120, 128, 138, 140-141, 146, 166-167, 171, 180, 189, 191, 193, 206, 213, 223-228, 233-234, 235-239, 241, 243-245, 249, 251, 254, 256-262, 264-267, 270, 278, 282-283, 287, 293-294, 296-306, 308, 312-315, 317-320, 336-337, 339, 342, 349, 357, 359, 361-362, 365-374, 376, 378, 381, 383-387, 389-394, 396-397, 401, 404-407, 409-413, 415-423, 426-430, 432-433, 436-439, 441-443, 452-454, 456-457, 459, 461-476, 483, 486-488, 492, 495, 497, 499-500, 503-504, 509, 512, 518-519, 523-527
Planck (Ley de), 44-45, 50, 67, 73, 110, 291-292
Polarización, 74-75, 78-80, 111, 117, 150-152
Probabilidad *a priori*, 409-411
Probabilidad *a posteriori*, 412
Puntos de control, 180, 300-301, 305-309, 313, 320, 431, 437, 526

Q

Quickbird, 28, 89, 93, 108, 137-139, 164, 176, 377

R

Radar, 21, 25, 29, 39, 73-75, 77-81, 87, 91, 93, 111-115, 117-119, 150-154, 157, 165, 204, 217, 227, 244, 259, 325, 376, 379-380, 414
Radarsat, 29, 73, 80, 93, 113, 117, 152-153
Radiación electromagnética, 49
Radiancia espectral, 48-49, 57, 68, 92, 165, 167, 271-272, 278
Radiómetro de micro-ondas, 137
Ráster (formato), 180, 229, 517, 524-525, 527
Ratón electrónico, 229, 234-235, 389
RBV *(Return Beam Vidicon)*, 109, 126, 128-129, 377
Realce del contraste, 245
Redes neuronales, 325, 336, 380, 422, 527
Reflectividad, 36, 48-49, 55-68, 73, 92, 95, 97, 146-147, 165-166, 171, 191, 193, 195, 197, 201, 203, 208-209, 225, 239-241, 249, 259, 270-280, 282-288, 290-292, 294, 298, 320-321, 324-329, 331-334, 336-339, 341-345, 350, 353, 357, 361-362, 365-366, 368-371, 385, 387, 398-399, 403, 413, 415, 430, 438, 444, 475, 517
Resolución, 25, 32-33, 36, 38-39, 59, 74, 88-95, 97-101, 103-107, 109-110, 112-114, 117, 119-120, 123, 125, 127-130, 132-135, 137-143, 145-147, 149-156, 162-163, 167, 170-172, 175-176, 183, 185, 190, 194, 196-197, 199-200, 202-203, 206-208, 210, 215, 219-221, 229, 233, 237, 242, 244-245, 259, 265, 276,

282, 294, 299-301, 320, 324, 328-330, 342, 359, 367, 369, 373, 376-377, 379, 382-383, 392, 418, 421, 429, 432, 434, 436-437, 440, 462-463, 465-466, 472-475, 478, 484-485, 490-491, 499, 509, 510, 517, 520-522
espacial, 25, 32, 38-39, 74, 84, 88-91, 97-98, 100, 103-105, 107, 109-110, 112, 117, 127-130, 132-135, 137-138, 140-143, 145, 149-154, 156, 162, 167,170-171, 175-176, 190, 199, 206-207, 215, 220, 229, 259, 276, 282, 294, 324, 328-329, 342, 367, 369, 373, 376-377, 382, 392, 434, 436-437, 440, 462-463, 466, 472-475, 478, 485, 490, 499, 509, 517, 521-522
espectral, 25, 59, 90-93, 97-98, 106, 154-155, 194, 208, 210, 299, 359, 485
radiométrica, 92-95, 137, 242, 244-245, 418, 517
temporal, 95, 98, 143, 152, 176, 330, 499
angular, 88, 97
RESURS, 104, 107, 154
RMS, 373, 375

S

SAC, 30, 144, 154
SAR, 113, 115-116, 118, 152
Saturación, 63, 195, 357-358, 360, 379
SAVI, 341, 343
Seawifs, 137, 300
Seasat, 25, 117, 151-152
Signatura espectral (ver firma espectral), 288, 338, 438
SIR *(Shuttle Imaging Radar)*, 117, 152
Sistemas de Información Geográfica (SIG), 20, 26, 28, 180, 183, 231, 234, 262, 282, 300, 320, 323, 377, 380, 430, 459-460, 470, 513, 515-527
Sistemas operativos, 25, 229-230
Skylab, 25, 100, 107
SLAR, 21, 73
Sol, 18, 44, 50, 52-53, 197, 201, 272, 281, 286, 288, 290
Space Shuttle, 22, 80, 102-104, 119, 151, 177, 435
SPOT, 25, 29, 91, 108, 123, 131-134, 150, 154, 170-171, 175-176, 185, 194, 203, 206-207, 219, 275, 277, 301, 303, 320, 330, 339, 369, 377, 379, 417, 455, 470, 485
Stefan-Boltzmann (Ley de), 51, 68,
Suelos, 18, 46, 60, 64-65, 68-71, 74-75, 78-80, 145, 155-156, 180, 191-192, 195-197, 219, 240, 294, 338, 350, 352, 354, 358, 365, 373, 380, 386, 389, 392-393, 399, 403, 412-414, 426, 438, 444, 458, 502, 518, 520

T

Tablas de color, 233, 242, 270
Tasseled Cap, 296, 352-353, 374, 438, 456
Temperatura, 36, 46, 48-53, 68-74, 82, 86, 88, 99, 110, 119, 142-145, 148, 151, 165-167, 180, 225, 254, 270, 291-296, 298-299, 321, 324, 327, 330-331, 368, 376, 380, 385, 419, 438, 440, 442, 455, 461, 470, 481, 483, 486, 491, 495-496, 499, 517, 520, 523, 527
Terra, 27, 29, 66, 84, 97, 123, 144-146, 156, 170, 203, 208, 276
Textura, 64, 67, 166, 168, 178-180, 189-190, 196-197, 200, 202, 205, 213, 219-220, 221, 380-381, 386-387, 389, 413-414, 416-417, 426, 460, 462, 466-470, 476, 485-486
TM, 34, 41, 66, 107, 127, 129-132, 136, 154, 170-171, 187-188, 195-196, 207-208, 215, 219, 239, 252, 267, 272, 273, 277, 280, 285, 292, 303, 308, 328-330, 339, 345, 353-354, 369, 377, 382, 436, 448-449, 451, 455, 458, 463, 466, 475-478, 485, 497, 509, 519
Tono, 77-78, 80-81, 85, 99, 117, 146, 167, 177-178, 189, 191, 193, 195-197, 200, 208-209, 213, 215, 223, 242-245, 251-254, 261, 350, 354, 357-358, 360, 379, 386-387, 414, 420, 439, 443-445, 447, 454, 459, 462
Transmisividad, 48-49, 53, 55, 68, 74, 83, 275, 278-280, 282, 293, 332-334

U

UTM, 300, 305, 317-319, 494

V

Variograma, 464-466, 476-477
Vectorial (formato), 431, 517, 523-524, 527
Vegetación, 18, 36, 39, 41, 46, 55-56, 59-64, 68-70, 74-75, 78, 80-81, 92, 100, 110, 117-119, 121, 141, 145, 147, 151, 155-156, 164, 167, 174, 179, 189, 191-192, 195-196, 200, 203, 213-215, 217, 231, 240, 254, 273, 279-280, 282, 287, 294, 296, 298, 308, 323, 326, 329-331, 333, 336-345, 350, 352-354, 358, 362, 364, 369, 373-376, 380-381, 385, 393, 399, 414, 421, 429, 437, 439-442, 444-445, 447, 449-450, 454-456, 458-459, 461-462, 466-467, 470, 475, 477, 488, 491, 498, 516-517, 520
Ventanas atmosféricas, 83
Vídeo (cámara), 99, 109-110, 126, 128, 149, 466
Visualización, 38, 164, 177-178, 194, 223, 229, 231-235, 237-238, 242-247, 251, 254-255, 266, 349, 379, 515, 517, 519

W

Wien (Ley de), 50, 52, 67, 110
Windows, 230

Z

Zoom, 236

ANEXO 4

FUENTES ADICIONALES DE INFORMACION

1. Centros internacionales dedicados a teledetección espacial

— *Australian Centre for Remote Sensing*, P. O. Box 28, Belconnen, A.C.T. 2616, Australia.
— *Canada Centre for Remote Sensing*, 588 Booth Street, CDN Ottawa, Ontario K1A 0Y7, Canadá.
— *DLR*, Forschungszentrum, Post Wessling/0BB, D-8031 Oberpfaffenhofen, Alemania.
— *Environmental Research Institute of Michigan (ERIM)*, P. O. Box 8618, Ann Arbor, Michigan, USA.
— *EROS Data Center*, National Mapping Division, Sioux Falls, SD 57198, USA.
— *European Space Agency*, 8-10 rue Mario Nikis, F-75738 París Cedex 15, Francia.
— *Groupement pour le Dévelopment de la Télédétection Aérospatial* (GDTA), Centre Spatiale de Toulouse, 18 Avenue Edouard Belin, F-31055 Toulouse.
— *ITC*, International Institute for Aerospace Survey and Earth Sciences, P. O. Box 6, NL-7500 AA, Enschede, Países Bajos.
— *Jet Propulsion Laboratory*, California Institute of Technology, 4800 Oak Grove Drive, Pasadena, CA91103, USA.
— *NASA Goddard Space Flight Center*, Greenbelt, MD 20771, USA.
— *National Remote Sensing Agency*, Balanagar, Hyderabad-500 037, India.
— *National Remote Sensing Center*, Space Department, Royal Aircraft Establishment, Farnborough, Hampshire GU14 6TO, Reino Unido.
— *National Space Development Agency of Japan (NASDA)*, 1401 Ohashi, Hotoyama-Machi, Hikigum, Saitama 350-03, Japón.
— *RESTEC, Remote Sensing technology Center of Japan*, Roppongi Fiorst Bldg, 2F, 1-9-9106 Tokio, Japón.
— *Space Applications Institute*, Joint Research Center, JRC-Ispra Site, 21020 Ispra, Varese, Italia.

2. Centros iberoamericanos dedicados a teledetección espacial
(ver también centros docentes)

— *Agencia de Medio Ambiente, Junta de Andalucía*, Servicio de Evaluación de Recursos Naturales, Pabellón de Nueva Zelanda, Avda. Acacias, s/n, Isla de la Cartuja, 41092 Sevilla, España.
— *Centro de Levantamientos Integrados de Recursos Naturales por Sensores Remotos* (CLIRSEN), Apartado 8216, Quito, Ecuador.

— *Centro de Procesamiento Digital de Imágenes* (CPDI) - *Instituto de Ingeniería*, Apartado 40200, Caracas 1040-A, Venezuela.
— *División de Aplicaciones de Imágenes Satelitarias* (DAIS), calle 7 num. 1267 - 2.º, La Plata, Rep. Argentina.
— *GEOCUBA*, Calle 4, num. 304, La Habana, Cuba.
— *Inisel Espacio,* Mar Egeo s/n, Polígono Industrial I, 28830 San Fernando de Henares, España.
— *Institut Cartogràfic de Catalunya,* Parc de Montjuïc, 08038 Barcelona, España.
— *Instituto Geográfico Nacional*, Sección de Teledetección, General Ibañez de Ibero, s/n. 28003 Madrid, España.
— *Instituto Geográfico Agustín Codazzi*, Carrera 30 No. 48-51, Bogotá D. E., Colombia.
— *Instituto Nacional de Pesquisas Espaciais* (INPE), Av. Dos Astronautas 1758, Sao José dos Campos - SP, Estado de Sao Paulo, Brasil.
— *Instituto Nacional de Estadística Geografía e Informática (INEGI),* Av. Héroes de Nacozari Sur 2301, Aguascalientes, 20290 México.

3. Sociedades Profesionales

— *American Society of Photogrammetry and Remote Sensing*, 5420 Grosvenor Lane, Suite 210, Bethesda 20814-2160, USA.
— *Asian Association on Remote Sensing,* Institute of Industrial Science, University of Tokio, 7-32 Roppongi, Minatoku, Tokio, Japón.
— *Asociación Española de Teledetección*, Pinar 25, 28008 Madrid.
— *Canadian Remote Sensing Society,* 222 Somerset Street West, Suite No. 601, Ottawa, Ontario K2P 0J1, Canada.
— *European Association of Remote Sensing Laboratories*, EARSeL Secretariat, 2 Avenue Rapp, F-75340 Paris Cedex 07, Francia.
— *International Society for Photogrammetry and Remote Sensing.*
— *Remote Sensing Society*, Department of Geography, University of Nottingham, Nottingham NG7 2RD, Reino Unido.
— *Sociedad de Especialistas Latinoamericanos en Percepción Remota* (SELPER), (sede para 1995 a 1997): *Universidad Nacional Autónoma de México - Instituto de Geografía,* Circuito Exterior, Ciudad Universitaria, Apdo. Postal 20850, 01000 México, D. F.

4. Centros docentes

— *Carnegie Laboratory of Physics, University of Dundee*, Dundee DD1 4HN, Escocia, Reino Unido.
— *Center for Remote Sensing, Imperial College of Science and Technology, Department of Physics*, Prince Consort Road, Londres SW7 2AZ, Reino Unido.
— *Environmental Remote Sensing Center, University of Winsconsin-Madison*, 1225 West Dayton Street, Madison, WI 53706, USA.
— *Instituto Geográfico Agustín Codazzi*, Carrera 30 No. 48-51, Bogotá D. E., Colombia.
— *International Institute for Aerospace Survey and Earth Sciences* (ITC), P. O. Box 6, NL-7500 AA, Enschede, Holanda.
— *Instituto Nacional de Pesquisas Espaciais* (INPE), Av. Dos Astronautas 1758, Sao José dos Campos - SP, Estado de Sao Paulo, Brasil.

— *Laboratory for Applications of Remote Sensing (LARS), Purdue University,* West Lafayette, IN 47907, USA.
— *Remote Sensing Unit,* Department of Geography, University of Nottingham. University Park, Nottingham NG7 2RD, Reino Unido.
— *Universidad de Alcalá de Henares, Departamento de Geografía.* Calle Colegios, 2. 28801 Alcalá de Henares, España.
— *Universidad Nacional Autónoma de México - Instituto de Geografía,* Circuito Exterior, Ciudad Universitaria, Apdo. Postal 20850, 01000 México, D. F.
— *Universidad de Valencia, Departamento de Termodinámica. Facultad de CC. Físicas,* Doctor Moliner 50, 46100 Burjassot, Valencia, España.

5. Revistas especializadas en teledetección

— *Canadian Journal of Remote Sensing,* Canadian Remote Sensing Society, 222 Somerset Street West, Suite No. 601, Ottawa, Ontario K2P 0J1, Canada.
— *Geocarto International*, Geocarto International Centre, GPO Box 4122, Hong Kong.
— *IEEE Transactions on Geoscience and Remote Sensing*, IEEE Geoscience and Remote Sensing Society, Institute of Electrical and Electronics Engineers Inc., 345 E. 47th Street, New York, 10017 USA.
— *International Journal of Remote Sensing*, Taylor & Francis Ltd., Rankine Road, Basingstoke, Hampshire RG24 0PR, Reino Unido.
— *ITC Journal*, International Institute for Aerospace Survey and Earth Sciences, P. O. Box 6, NL-7500 AA, Enschede, Países Bajos.
— *Photogrammetric Engineering and Remote Sensing*, American Society for Photogrammetry and Remote Sensing, 5420 Grosvenor Lane, Suite 210, Bethesda 20814-2160, USA.
— *Photointerprétation*, Editions Technip, 27 rue Ginoux, F75737, París Cedex 15, Francia.
— *Remote Sensing of Environment*, Elsevier Science Publishing Company Inc., 52 Vanderbilt Avenue, New York, 10017, USA.
— *Remote Sensing Quarterly*, University of Nebraska at Omaha, Omaha, Nebraska 68182.
— *Remote Sensing Reviews*, Harwood Academic Publishers, 50 W. 23rd Street, New York, 10010, USA.
— *Revista de Teledetección*, Asociación Española de Teledetección (www.aet.org.es).
— *Soviet Journal of Remote Sensing*, Harwood Academic Publishers, 50 W. 23rd Street, New York, 10010, USA.

6. Recopilaciones bibliográficas

— *Earth Resources: A Continuing Bibliography with Indexes*, NASA, U.S. National Aeronautics and Space Administration, Washington, D. C., 20546, USA.
— *Geographical Abstracts, G: Remote Sensing, Photogrammetry and Cartography*, Geo Abstracts Ltd., Regency House, 34 Duke Street, Norwich NR3 3AP, Reino Unido.
— GEOBASE, Geo Abstracts Ltd. (base de datos informatizada).
— *Remote Sensing of Natural Resources: A Quarterly Literature Review*, University of New México, Technology Application Center, Alburquerque, NM 87131, USA.
— RESORS (*Remote Sensing Online Retrieval System*), Canada Center for Remote Sensing, Department of Energy, Mines and Resources, 588 Booth Street, CDN Ottawa, Ontario K1A 0Y7, Canadá.

7. Organismos dedicados a la distribución de imágenes

— *Earthwatch,* 1900 Pike Road, Longmont, Colorado 80501, USA.
— *EOSAT (Earth Observation Satellite Company)*, 4300 Forbes Boulevard, Lanham, MD 20706, USA. Representantes españoles: (a) Infocarto, Gobelas, 25 - 3º, 28023 Madrid; (b) Ibersat, Velázquez 24 - 5º, 28001 Madrid.
— *INTA - División Ciencias del Espacio* (representante español de la red europea EARTHNET), Carretera de Ajalvir, km. 4, 28850 Torrejón de Ardoz, España.
Imágenes de la estación espacial internacional: http://www.earthkam.ucsd.edu/public/about/
— *NOAA (National Oceanic and Atmospheric Administration)*, NESDIS, World Weather Building, Room 100, Washington, D. C. 20233, USA.
— *Radarsat International*, 3851 Shell Rd, Suite 200, CDN-Richmond, B. C. V6X 2W2, Canadá.
— *SOJUZKARTA*, 45 Volgogradski Pr., Moscú, 109125, Rusia.
— *SPOT-Image*, 5 rue des Satelites, Toulousse, B.P. 4359, F-31030, Francia. Representante español: Aurensa, San Francisco de Sales 38 - 1º, 28003 Madrid.
— *U.S.Geological Survey, EROS Data Center*, Sioux Falls, SD 57198.

8. Empresas dedicadas a la fabricación de equipos de tratamiento digital de imágenes

— DRAGON, Six University Drive Suite 213, Amherst, MA 01002, USA.
— ENVI, Research Systems Inc., 2995 Wilderness Place, Boulder, CO 80301, USA. Representante español: Estudio Atlas, Tomas Meabe 15, 28019 Madrid.
— ERDAS, 430 Tenth Street, N.W., Suite N206, Atlanta, GA 30318. Representante español: Infocarto, Gobelas, 25 - 3º, 28023 Madrid.
— ER-Mapper, 87 Colin Street, West Perth, Western Australia 6005. Representante español: Tragsatec, Avda. Ciudad de Barcelona, 118-124, 28007 Madrid, e Ibersat, Araquil, 11, 28023 Madrid.
— ESRI, 380 Nueva York St. Redlands CA92373, USA. Representante español: ESRI España, Princesa, 3 - 7 Planta, 28008 Madrid.
— Idrisi, Clark University, Clark Labs for Cartographic Technology and Geographic Analysis, 950 Main Street, Worcester MA 01610-1477, USA.
— Ilwis, International Institute for Aerospace Survey and Earth Sciences (ITC), P. O. Box 6, NL-7500 AA, Enschede, Holanda.
— Intergraph, One Madison Industrial Park, Mail Stop IW17 B6, Huntsville, Alabama 35894, USA.
— PCI, 50 Est Wilmot Stree, L4B 1M5 Richmond Hill, Canada. Representante español:
— Terra-Mar, 1937 Landings Drive, Mountain View, CA 94043, USA.
— TNT, Micro-images Inc., 201 North 8th Street, Lincoln, NE 68508-1347, USA.

9. Asociaciones profesionales

— Asociación americana de fotogrametría y teledetección: ASPRS: www.asprs.org
— Asociación Española de Teledetección: www.aet.org.es
— RSPSoc - Remote Sensing & Photogrammetry Society: http://www.rspsoc.org/
— SELPER: http://www.selper.org/

ANEXO 5

SITUACIÓN Y CARACTERÍSTICAS DE LAS IMÁGENES UTILIZADAS EN LOS CAPÍTULOS 6 Y 7

1. *Denominación en el texto:* Torre100
   Sensor: Landsat-ETM+
   Fecha de adquisición: 15-03-2000
   Hora: 10:48 GMT
   Acimut solar: 146,58º
   Elevación solar: 42,39º
   Calibración: Ver tabla 6.5

2. *Denominación en el texto:* Madrid02
   Sensor: Landsat-ETM+
   Fecha de adquisición: 12-08-2002
   Hora: 10:43 GMT
   Acimut solar: 133,34º
   Elevación solar: 57,01º
   Calibración: Ver tabla 6.5

3. *Denominación en el texto:* Barrax99
   Sensor: Hymap
   Fecha de adquisición: 3-06-1999
   Hora: No disponible
   Acimut solar: No disponible
   Elevación solar: No disponible
   Calibración: Coeficientes proporcionados por la campaña Daisex

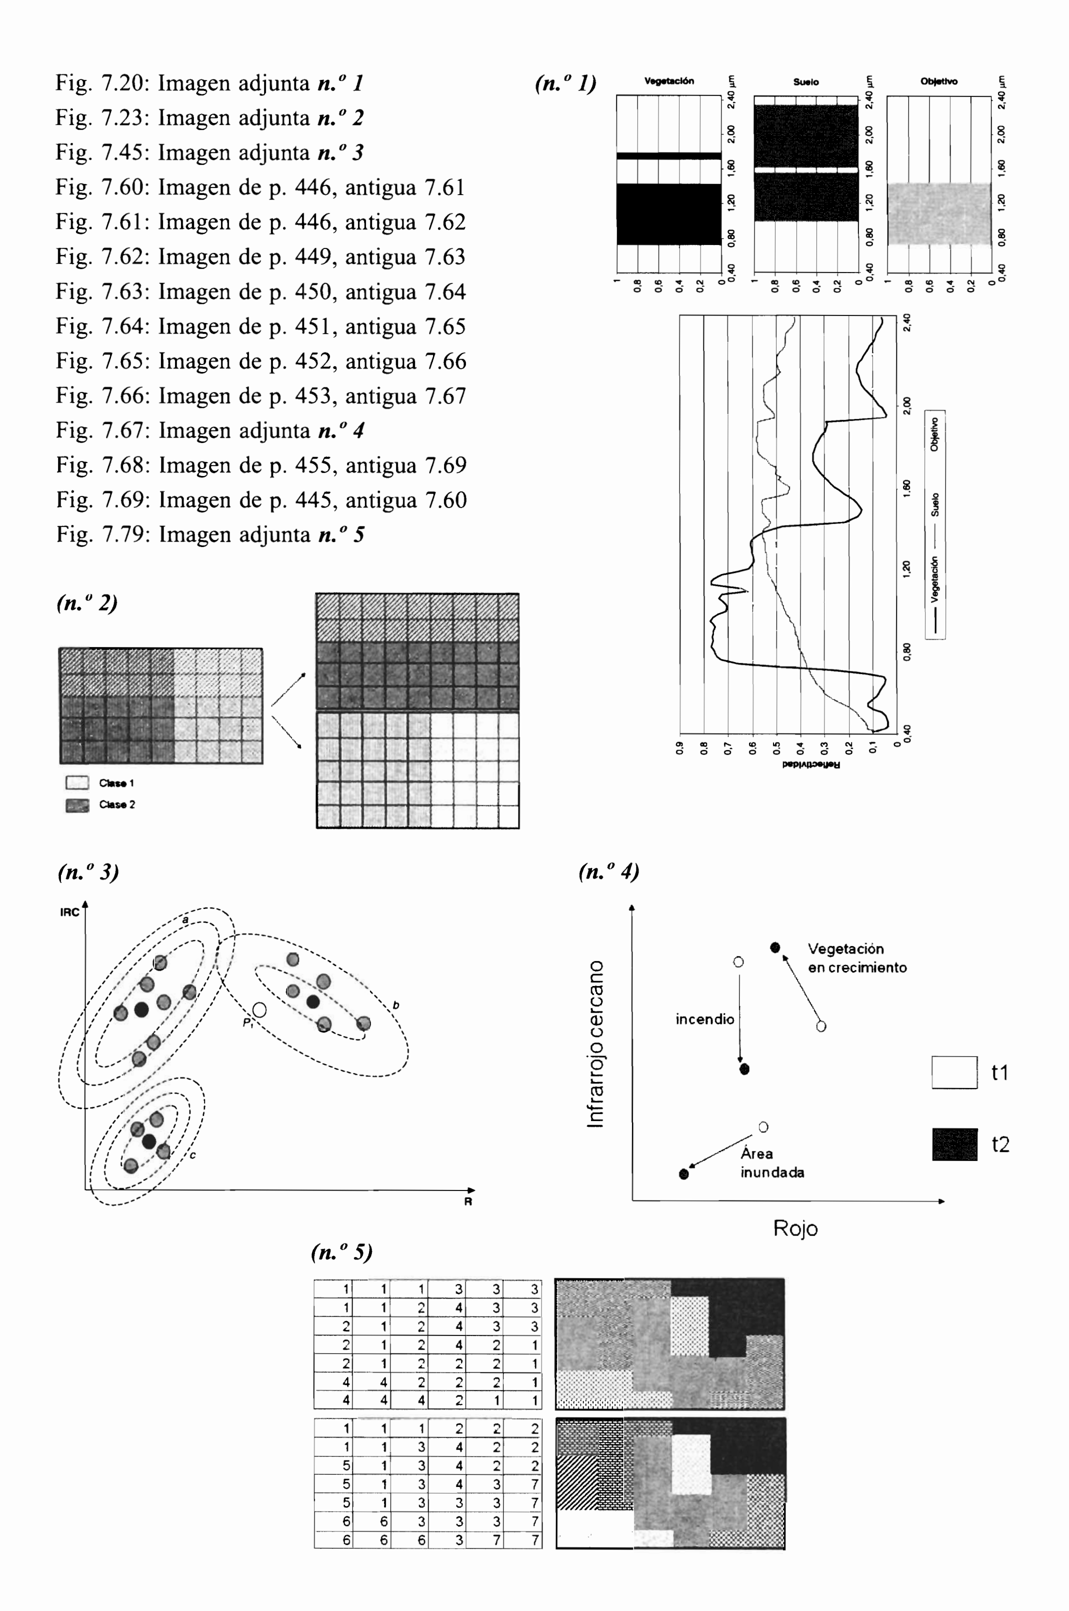
4. *Denominación en el texto:* Madrid00
   Sensor: Landsat-ETM+
   Fecha de adquisición: 15-03-2000
   Hora: 10:48 GMT
   Acimut solar: 146,58º
   Elevación solar: 42,39º
   Calibración: Ver tabla 6.5

5. *Denominación en el texto:* Madrid92
   Sensor: Landsat-TM
   Fecha de adquisición: 13-08-1992
   Hora: 10:18 GMT
   Acimut solar: 129,62º
   Elevación solar: 50,47º
   Calibración: Ver tabla 6.5

FE DE ERRATAS

Pág.	*Donde dice*	*Debe decir*
272	[Chander, 2004 #5085].	(Chandler *et al.*, 2004).
277	[Kruse, 2004 #5086].	(Kruse, 2004).
277	[Schaaf, 2002 #4303].	(Schaaf *et al.*, 2004).
296	[National Research Council, 2007 #5010].	(National Research Council, 2007).
299	[Khlopenkov, 2007 #4951].	(K. V. Khlopenkov y A. P. Trishchenko, 2007).
	[Ackerman, 1998 #4362].	(Ackerman *et al.*, 1998).
333	(Rencz, 1999, #3253; Zarco-Tejada, 1999, #3263):	(Rencz y Ryerson, 1999; Zarco-Tejada *et al.*, 1999):
	(Verhoef, 1984, #3289).	(Verhoef y Peteri, 1984).
358	(Koutsias, 2000, #2860)	(Koutsias *et al.*, 2000)
362	(Mazer, 1988 #3298).	(Mazer *et al.*, 1988).
402	[ ];	{ };
	(Kumar, 1977, #360):	(Kumar y Silva, 1977):
404	$d_{x,A} = \sqrt{\sum_{i=1,m}(END_{x,i} - \overline{\mathrm{ND}}_{A,i})^2}$	$d_{x,A} = \sqrt{\sum_{i=1,m}(ND_{x,i} - \overline{\mathrm{ND}}_{A,i})^2}$
423	[Rumelhart, 1986, #1123}	Rumelhart *et al.*, 1986
424	[Civco, 1993, #2533]).	[Civco, 1993]).
435	(Martínez Vega, 1989, #1268).	(Martínez Vega, 1989).
467	(Salas, 1995, #1371; Riaño, 2001, #3313; Yool, 1985, #576).	(Salas y Chuvieco, 1995; Riaño *et al.*, 2001; Yool *et al.*, 1985).
	(Strahler, 1978, #1672; Strahler, 1984, #519).	(Strahler *et al.*, 1978).
468	$\mathrm{EL} = \sqrt{(\widehat{c}_i - c_i)^2 + (\widehat{l}_i - l_i)^2}$	$\mathrm{C} = \sum_{i=0,n-1}\sum_{j=0,n-1}\left(p_{i,j}\left\|F_i - L_j\right\|\right)$
474	(1998, #3667)	(1998)
	(Frohn, 1998, #3667).	(Frohn, 1998).
510	Bolivia (*b*).	Bolivia (*b*). Tomado de Chuvieco *et al.*, (2008*c*).

Fig. 7.20: Imagen adjunta ***n.º 1***
Fig. 7.23: Imagen adjunta ***n.º 2***
Fig. 7.45: Imagen adjunta ***n.º 3***
Fig. 7.60: Imagen de p. 446, antigua 7.61
Fig. 7.61: Imagen de p. 446, antigua 7.62
Fig. 7.62: Imagen de p. 449, antigua 7.63
Fig. 7.63: Imagen de p. 450, antigua 7.64
Fig. 7.64: Imagen de p. 451, antigua 7.65
Fig. 7.65: Imagen de p. 452, antigua 7.66
Fig. 7.66: Imagen de p. 453, antigua 7.67
Fig. 7.67: Imagen adjunta ***n.º 4***
Fig. 7.68: Imagen de p. 455, antigua 7.69
Fig. 7.69: Imagen de p. 445, antigua 7.60
Fig. 7.79: Imagen adjunta ***n.º 5***



1	1	1	3	3	3
1	1	2	4	3	3
2	1	2	4	3	3
2	1	2	4	2	1
2	1	2	2	2	1
4	4	2	2	2	1
4	4	4	2	1	1

1	1	1	2	2	2
1	1	3	4	2	2
5	1	3	4	2	2
5	1	3	4	3	7
5	1	3	3	3	7
6	6	3	3	3	7
6	6	6	3	7	7